

UNIVERSIDAD CARLOS III DE MADRID
DEPARTAMENTO DE INGENIERÍA DE SISTEMAS Y
AUTOMÁTICA



INGENIERÍA INDUSTRIAL

PARAMETRIZACIÓN DE UNA RED
NEURONAL PARA LA MEJORA DE LA
PREDICCIÓN DE LA IRRADIANCIA
DIRECTA NORMAL

PROYECTO DE FIN DE CARRERA

AUTOR: ALEJANDRO RODRÍGUEZ DELGADO
TUTOR: PIOTR JUREWICZ SLUPSKA

2011

TÍTULO: Parametrización de una red neuronal para la mejora de la predicción de la Irradiancia Directa Normal

AUTOR: Alejandro Rodríguez Delgado

DIRECTOR: Piotr Jurewicz Slupska

EL TRIBUNAL

Presidente:

Vocal:

Secretario:

Realizado el acto de defensa y lectura del Proyecto Fin de Carrera el día __ de ____ de 20__ en Leganés, en la Escuela Politécnica Superior de la Universidad Carlos III de Madrid, acuerda otorgarle la CALIFICACIÓN de

VOCAL

SECRETARIO

PRESIDENTE

Al esfuerzo realizado

AGRADECIMIENTOS

En primer lugar me gustaría agradecerle la ayuda y atención prestada a mi tutor de proyecto, Piotr. Su constante interés en la evolución de mi trabajo ha sido fuente de motivación para mí en toda la elaboración de este documento.

A Jaime, por la oportunidad de realizar este proyecto, y su ayuda permanente en el trabajo durante el último año.

Al equipo de Sun to Market Solutions, porque su compañerismo y amistad han sido fundamentales para mí durante mi estancia allí. Sobre todo a Héctor, por su incommensurable apoyo en todo momento, tanto bueno como no tanto.

A Susana, Vela, Leti, Jacobo, Deni, Reyes, Elena, Pérez, Trejo y Pablo por su ayuda y amistad en la universidad a lo largo de los años.

A Elías, Óscar, Jorge, Mario, César, Carlos, Javi y Almu por los buenos ratos pasados y por aguantarme.

A toda mi familia por su apoyo ilimitado; a mis primas Blanca y Marian y mi tía Charo por el cariño que siempre me han mostrado.

A mi hermana Lorena por servirme de ‘chispa’ muchas veces en mi vida.

Y especialmente a mis padres por haberme brindado esta oportunidad y porque sin ellos no habría sido posible llegar aquí.

RESUMEN

Este documento trata sobre la parametrización de una red neuronal para la mejora de un modelo de predicción meteorológica, en concreto de la variable con mayor relevancia dentro del sector industrial de la tecnología termosolar: la *Irradiancia Directa Normal* (*DNI*). El objetivo del proyecto es disminuir el error cometido en dicha predicción. Para ello se ha efectuado una simulación de las variables meteorológicas para una región dada (Madrid) para los años 2008 y 2009. Con dichas variables se han obtenido los valores de DNI correspondientes mediante un modelo físico (*MRM*) implementado en Matlab. Estos valores serán utilizados en la búsqueda de la combinación de parámetros que sirva para entrenar la red neuronal más efectiva.

ABSTRACT

This document explains the process of parameterization for the improvement of a meteorological forecasting model. In particular, forecasting the *Direct Normal Irradiance* (*DNI*). The objective of the project is to decrease the error committed. With this aim, meteorological variables have been simulated for one region (Madrid), for the years 2008 and 2009. The corresponding values of DNI have been obtained by means of a physical model (*MRM*) implemented in Matlab. These values will be used to look for the combination of parameters that trains the most effective neural network.

GLOSARIO DE TÉRMINOS METEOROLÓGICOS

Dado que los siguientes términos aparecen constantemente a lo largo de todo el documento, se ha agregado este glosario con el fin de que el lector se familiarice con ellos.

DNI: *Direct Normal Irradiance*. Fracción de la irradiancia solar que llega a la superficie terrestre con una trayectoria bien definida hasta una posición determinada y puede ser concentrada.

DHI: *Diffuse Horizontal Irradiance*. Fracción de la irradiancia solar que llega a la superficie terrestre sin una trayectoria definida y por tanto, no puede ser concentrada.

Elevación: el ángulo de elevación es el ángulo que forma el Sol, el observador y la superficie horizontal sobre la que se sitúa éste.

GFS: *Global Forecast System*. Modelo numérico de predicción meteorológica a nivel de todo el globo terráqueo.

GHI: *Global Horizontal Irradiance*. Es el total de la irradiancia, es decir, la suma de las componentes de irradiancia directa normal y difusa respecto de un plano horizontal.

HR: humedad relativa del aire.

Índice de nubosidad: coeficiente comprendido entre 0 y 1 indicativo de la nubosidad existente entorno a un emplazamiento dado.

Irradiancia: término utilizado para describir la potencia incidente por unidad de superficie de todo tipo de radiación electromagnética.

MRM: *Meteorological Radiation Model*. Modelo físico de parámetros atmosféricos usado para el cálculo de las diferentes componentes de la irradiancia solar.

P: presión atmosférica.

Parámetro de turbidez: parámetro indicativo de la turbiedad de la atmósfera entorno a un emplazamiento dado.

Radiación: fenómeno basado en la propagación de energía en forma de ondas elec-

tromagnéticas o partículas subatómicas a través del vacío o de un medio material.

T: temperatura ambiente.

WRF: *Weather Research and Forecasting model*. Modelo numérico de predicción meteorológica para una región dada.

ΔT : variación de la temperatura. Calculada como la diferencia $T_{i+1} - T_i$ en las series temporales horarias de temperatura.

CAPÍTULO 1

INTRODUCCIÓN

El término desarrollo sostenible apareció por primera vez a finales de los años 80. Este se definiría como aquel que satisfaga las necesidades de las generaciones presentes sin comprometer las posibilidades de las del futuro para atender sus propias necesidades. Este escenario podría segmentarse en tres partes: económico, ecológico y social.

De esta forma, las energías renovables empezaron crecer en importancia en la producción de energía eléctrica. Como es bien sabido, las energías renovables son inagotables, usan tecnologías '*limpias*' y se han visto favorecidas por un aumento considerable en su inversión gracias a las exenciones fiscales dadas a los proyectos de esta índole. Hoy en día ya se puede ver que la cantidad de energía procedente de energías renovables en España es significativa.

Por otra parte, a pesar de todas las ventajas que tienen este tipo de energías, no dejan de tener algunos inconvenientes, como las bajas eficiencias y la aleatoriedad y dificultad de predicción del recurso a aprovechar (sol, viento...). Cabe comentar que entre las tecnologías disponibles para el uso de energías renovables únicamente la eólica y la solar térmica presentan expectativas para tener un papel importante en las próximas décadas en la producción eléctrica.

La tecnología termosolar aprovecha la energía procedente del sol, habiendo realizado previamente una concentración de la radiación solar. La dificultad que entraña esta tecnología es la arbitrariedad con la que se dispone del recurso solar: la presencia de nubosidad y partículas sobre el emplazamiento de los concentradores reduce sustancialmente la capacidad de producción de la planta, recurriéndose al uso de almacenamientos para solventar este problema.

Por ello, es deseable un optimizador de la planta que permita combinar las estrategias de operación con la disponibilidad de energía para maximizar la rentabilidad. De igual manera, es necesario un sistema de predicción del recurso en un horizonte temporal pequeño (24,48 o 72 horas). Este problema ha surgido con el desarrollo de dicha tecnología y por tanto, es relativamente nuevo, no habiéndose realizado demasiada investigación en el tema. En cualquier caso, modelos físicos y técnicas estadísticas han sido desarrollados con cierta eficacia, aunque resultando inexacta la predicción en condiciones de nubosidad.

En el presente proyecto se ha efectuado la parametrización de una red neuronal, con

el fin de añadirla a la salida de un sistema de predicción meteorológica. Este está compuesto a su vez de diferentes modelos.

El sistema consiste de un modelo numérico de predicción de gran escala (*GFS*), cuyas variables meteorológicas de salida son a su vez entradas de otro modelo de menor escala (*WRF*). De éste, ciertas variables de interés son obtenidas (presión, temperatura, humedad relativa, etc). A continuación algunas de ellas son utilizadas para la estimación de la radiación solar mediante un modelo físico (*MRM*). Un esquema del sistema de predicción con la red neuronal añadida se presenta en la figura 1.1.

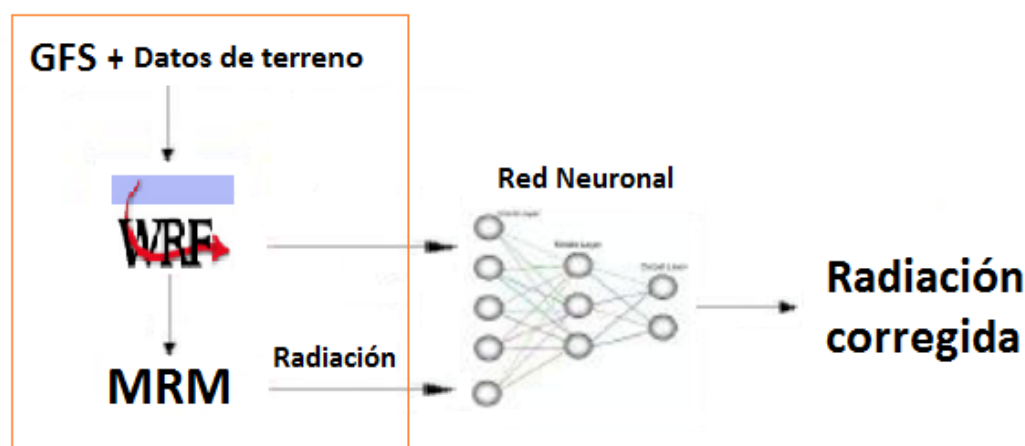


Figura 1.1: Esquema del modelo de predicción.

1.1. OBJETIVO

Dadas una serie de valores de la radiación solar estimados mediante un modelo físico y una muestra de valores medidos en una ubicación determinada, se ha tratado de buscar la mejor combinación de parámetros de una red neuronal artificial usando variables meteorológicas de tal manera que se redujera el error cometido en dicha estimación.

1.2. FASES Y RESUMEN DEL PROYECTO

Se puede dividir en tres fases:

1. Se ha realizado una simulación meteorológica para el área de Madrid. En concreto, se han obtenido las variables meteorológicas para el entorno del centro de investigación de Ciemat en Ciudad Universitaria (40.4528° N, 3.7242° O) para los años 2008 y 2009, con una resolución temporal horaria.
2. A continuación, con las variables de dicha área se han obtenido los valores más próximos a las coordenadas geográficas concretas y se han calculado los valores

de radiación correspondientes mediante un modelo físico implementado en Matlab (MRM).

3. Se ha llevado a cabo la parametrización de la red neuronal, posterior a un breve análisis de los datos usados en el entrenamiento. Se han entrenado las redes con el año 2008 y se ha tratado de predecir el 2009. Esta tercera fase es el objeto del proyecto.

1.3. ESQUEMA DEL DOCUMENTO

En el presente documento se presentan los resultados de realizar la parametrización de una red neuronal añadida a un modelo de predicción.

El documento consiste de seis capítulos además del actual:

- Los capítulos del 2 al 6 son de contenido teórico. En él se explican desde aspectos más generales, como puede ser el estado del arte a consideraciones más específicas relacionadas con la elaboración del proyecto, en diferentes cuestiones como la tecnología termosolar, la radiación solar, los modelos numéricos de predicción meteorológica y las redes neuronales.
- Se ha desarrollado un capítulo a continuación para la obtención de datos de la simulación con la posterior explicación de las pruebas realizadas y análisis de los resultados obtenidos.
- Finalmente se han expresado las conclusiones obtenidas del trabajo realizado.

1.4. ENTORNO DE TRABAJO

El proyecto ha sido efectuado en la empresa *Sun to Market Solutions*. Esta empresa participa activamente en proyectos de ingeniería y desarrollo en plantas termosolares y fotovoltaicas proponiendo soluciones y soporte técnico. Aporta conocimiento, experiencia legal, económica y medioambiental para otras compañías, gobiernos, bancos o inversores. Trabaja en un entorno internacional, dando servicio a clientes de un amplio rango de países del mundo.

CAPÍTULO 2

INTRODUCCIÓN A LA TECNOLOGÍA TERMOSOLAR

En este capítulo se explicará los diferentes tipos de tecnología existentes en la industria, centrándose en la que es de interés en este proyecto: la tecnología termosolar. Se procederá a comentar alguna de sus peculiaridades y finalmente se realizará un resumen de la situación actual en España de dicha tecnología basado en datos de la Asociación Española de la Industria Solar Termoeléctrica [1].

2.1. TIPOS DE TECNOLOGÍA

La energía solar aprovecha la radiación procedente del sol sobre una superficie captadora que transformará en otro tipo de energía dependiendo de su finalidad. Así pues, hay dos grandes tipos de energía solar: fotovoltaica y termosolar.

La energía fotovoltaica transforma la radiación directamente en electricidad. Los fotones de la radiación solar inciden sobre un metal que, superado cierto umbral, produce el movimiento de electrones y por tanto, generación de electricidad.



Figura 2.1: Panel fotovoltaico.

La energía termosolar utiliza la capacidad térmica de un fluido caloportador para aprovechar dicha radiación. Dentro de la energía termosolar la podemos clasificar según la temperatura del fluido de trabajo:

- Baja temperatura para agua caliente sanitaria, calefacción y frío solar hasta 100-150°C.
- Media temperatura, desde 100°C hasta 200-300°C usándose en procesos industriales.
- Alta temperatura, para aplicaciones industriales hasta 1000°C.

Para aplicaciones termoeléctricas el fluido calentado se usará para producir vapor sobrecalentado en un intercambiador de calor que posteriormente será utilizado en una turbina para la generación de electricidad. Con este propósito se han desarrollado diferentes tecnologías, mostrándose a continuación solamente las más importantes. Pero antes de ello cabe definir las partes de un colector solar:

- *Colector*: sistema completo, receptor más concentrador.
- *Receptor*: elemento donde se absorbe la radiación solar y se convierte en otra forma de energía.
- *Concentrador*: parte del colector que dirige la radiación hacia el receptor. Puede ser reflector o refractor, cilíndrico o superficie de revolución y continuo o segmentado. Normalmente exige orientación, es decir, sistema de seguimiento.

Aumentando la relación de concentración de los colectores aumentan las temperaturas de trabajo pero también los requerimientos al sistema óptico y de seguimiento lo que produce un aumento considerable de los costes.

- *Centrales de colectores cilindro-parabólicos*: estas centrales son las formadas por campos solares de colectores de espejo con una superficie parabólica. El receptor es generalmente tubular y va encapsulado en otro tubo de mayor diámetro, habiéndose hecho vacío entre ambos. A través del tubo circula el fluido caloportador. Se usan para relaciones de concentración intermedias de hasta 500°C siendo habitual temperatura de 400°C. Estos colectores están programados para realizar un seguimiento del sol y para maximizar la captación de energía solar. El seguimiento lo realiza en un solo eje: Norte - Sur y Este - Oeste.



Figura 2.2: Colector cilindro parabólico.

- *Centrales de torre*: los sistemas de receptor central están formados por un campo de espejos heliostatos de enorme tamaño los cuales realizan el seguimiento del sol en dos ejes. El campo de heliostatos apunta a un intercambiador de calor situado en la parte superior de una torre central. El gran número de heliostatos y su tamaño hacen que el campo solar ocupe una gran superficie. Además, en un sistema de este tipo hay que considerar otros efectos ópticos como por ejemplo las sombras producidas por colectores vecinos lo que requiere espaciarlos adecuadamente o bien bloqueos producidos por la torre. Se consiguen temperaturas de concentración entre 550 y 1500°C. El diseño y la operación de este tipo de sistemas es mucho más complejo que el del caso anterior. Existen dos explotaciones comerciales en España hasta el momento aunque las perspectivas de crecimiento son buenas.




Figura 2.3: Campo de heliostatos y torre.

- *Generadores solares disco-parabólicos*: son colectores con algún tipo de simetría circular cuyo concentrador, generalmente compuesto de una o varias superficies de revolución, refleja la radiación hacia un receptor puntual. La forma más comúnmente usada en el concentrador es el paraboloide de revolución, cuya geometría resulta de girar entorno a un eje central el perfil de un cilíndrico-parabólico. El seguimiento del sol es en dos ejes. Se consiguen temperaturas hasta 1500° siendo una temperatura habitual del fluido a calentar unos 750°C. Para realizar la conversión a electricidad motores con ciclo Stirling son los más usados y los que más perspectivas de futuro tienen.




Figura 2.4: Esquema y fotografía de receptor cilindro parabólico.

- *Fresnel*: consiste en filas de colectores solares que reflejan la radiación hacia un receptor lineal por el que circula fluido caloportador. La principal diferencia respecto de los colectores cilíndrico parabólicos es que en esta configuración en vez de tener un reflector parabólico ahora cada tubo tendrá varios que pueden ser controlados independientemente. Por el momento simplemente se han realizado pruebas en instalaciones piloto sin objetivo comercial.



Figura 2.5: Colectores en disposición Fresnel.

Cabe mencionar que en todas estas tecnologías es un factor clave mantener un rendimiento óptico de los espejos adecuado, es decir, mantener unos niveles de limpieza considerables y que el seguimiento se realice con cierto grado de precisión.

Las centrales de colectores cilindro-parabólicos y de torre son las más desarrolladas hasta la fecha y comparten la misma idea.




Figura 2.6: Esquema de una central de torre.

Estas centrales usarán el vapor de agua generado en un ciclo Rankine, con o sin modificaciones (con recalentamiento o con extracciones). El ciclo Rankine trata de emular al ciclo de Carnot, que es el rendimiento teórico máximo. El ciclo de Carnot se produce cuando en presencia de dos focos de temperatura, una máquina trabaja absorbiendo una cantidad de calor Q_1 del foco caliente y cediendo un calor Q_2 a la de baja temperatura produciendo un trabajo sobre el exterior. El rendimiento será:

$$\eta = \frac{W}{Q_1} = \frac{Q_1 - Q_2}{Q_1} = 1 - \frac{Q_2}{Q_1} = 1 - \frac{T_2}{T_1} \quad (2.1)$$




Figura 2.7: Ciclo teórico de Carnot en diagrama P-V y T-S respectivamente.

Este ciclo consta de cuatro etapas:

- Absorción de calor del foco caliente a temperatura constante (1-2).
- Expansión isentrópica (2-3).
- Cesión de calor al foco frío a temperatura constante (3-4).
- Compresión isentrópica (4-1)

En el ciclo ideal de Rankine, se produce vapor debido a la transferencia de calor desde un producto o fuente energética, se produce una expansión isentrópica del vapor sobrecalentado en una turbina transfiriéndole energía cinética a ésta que se aprovechará para la producción de electricidad mediante un generador eléctrico. A continuación el fluido cambia a fase líquida en un condensador, que no es más que un intercambiador de calor. Finalmente, una vez obtenido líquido este se comprime en una bomba para volver a producirse el aporte de calor. Asimismo, se tratará de aumentar la presión de la caldera y disminuir la presión del condensador.




Figura 2.8: Ciclo Rankine teórico y real.

Se puede apreciar que las compresiones y expansiones isentrópicas no existen realmente, si no que siempre se produce irreversibilidades, aumentos de entropía. Además, el aporte de calor se realiza en tres subetapas. Primero se calienta líquido subenfriado, para realizarse el cambio de fase y posteriormente prolongar el calentamiento del vapor sobrecalentado. Aunque a veces se evita esto en casos como las centrales nucleares que tienen que cumplir requisitos de seguridad altos. Existen muchas modificaciones del ciclo Rankine como ponerle en este punto un recalentamiento, escalonando las expansiones o mediante la realización de extracciones de vapor con el fin de aumentar el rendimiento del ciclo.

Desde el punto de vista de la generación de electricidad, la turbina tiene que evitar fluctuaciones de carga. Dada la gran aleatoriedad de los fenómenos meteorológicos esto no es tarea sencilla, por lo que se debe recurrir a almacenamientos. El sistema de almacenamiento permite acortar los tiempos de arranque y eliminar transitorios que se puedan producir debido a la aleatoriedad del recurso solar (por nubes, etc).

La configuración de los almacenamientos vendrá dada por la estrategia de operación que se quiera implementar en la central. Así, se podrá optar por evitar transitorios utilizando almacenamientos de corta duración con gran capacidad de respuesta. En cambio, si se opta por aumentar el periodo de producción de la planta se deberán utilizar almacenamientos de mayor tamaño.

A pesar la existencia de diferentes tipos de almacenamientos solo algunos de ellos son viables teniendo en cuenta la rentabilidad de la planta. Con diferencia la industria

suele recurrir a almacenamientos térmicos. En ellos el factor clave desde el punto de vista técnico es el obtener una elevada densidad energética para cumplir los requisitos con un mínimo de volumen. Otro aspecto importante es la correcta transferencia de calor entre el almacenamiento y el fluido calorífero. Se pueden clasificar como:

- *Calor sensible*: en el almacenamiento de calor sensible la energía es acumulada en un material a una temperatura determinada. Dicho material no sufre cambios de fase y puede ser sólido líquido o combinación de ambos. Algunos de los más usados son agua, aceites naturales o sintéticos, sales fundidas y metales líquidos. Este tipo pueden encuadrarse dentro de dos subgrupos: directos e indirectos. En los primeros es el mismo fluido de trabajo el que se usa en el campo solar y en los almacenamientos; en el segundo se recurre a un intercambiador de calor, con las pérdidas térmicas que este lleva asociadas.
- *Calor latente*: en el almacenamiento de calor latente, se aprovecha el cambio de fase de los materiales para almacenar calor, por lo que teóricamente este se mantendrá a temperatura constante.

Además, este tipo de plantas suelen poseer un sistema de hibridación fósil, o sea, una caldera de apoyo. Se pueden emplear diferentes combustibles como gasóleo, biogases procedentes de biomasa, siendo el gas natural el más usado. En concreto, en el RD 661/2007 se especifica que se puede realizar la quema de combustible para mantener la temperatura del fluido transmisor de calor para compensar la falta de irradiación solar que pueda afectar a la entrega prevista de energía. La entrega del combustible se realizará desde una planta situada en las proximidades.

Como se ha dicho, deben ser tenidos en cuenta tanto el sistema de hibridación como la configuración de los almacenamientos a la hora de elaborar una estrategia de operación de la planta. Por ello, el tener un sistema de predicción de la energía solar para las futuras 24, 48 o 72 horas es un factor clave.

2.2. ESTADO ACTUAL DE LA TECNOLOGÍA TERMOSOLAR EN ESPAÑA

En la figura 2.10 vienen dados los proyectos de plantas termosolares operativas, en construcción avanzada y preasignados. Como es lógico, la gran mayoría de los emplazamientos están en zonas meridionales de España debido al mayor recurso solar disponible (figura 2.9). Además, la mayoría de las centrales operativas o en proyecto de construcción usan la tecnología de colectores cilindro-parabólicos, a excepción de la PS10 y PS20 y Gemasolar, que son centrales de torre; las dos de Puerto Errado, que usan tecnología Fresnel y Casa del Ángel de discos parabólicos. Sin embargo, de las centrales preasignadas si que se aprecia un incremento a favor de esta tecnología (discos parabólicos) con la construcción de 70 MW de potencia en Ciudad Real.

Tabla 2.1: Potencia de centrales termosolares en España en 2010 y 2011.

Estado	Potencia 2010 (MW)	Potencia 2011 (MW)	Incremento (%)
Operativa	382.2	788.4	106
Construcción avanzada	717.5	881	23
Preasignada	1374.2	842	-40
Total	2473.9	2511	2

Siguiendo esos mismo datos, el total de potencia instalada en Julio de 2011 en España es de 788.4 MW. A principios de 2010 la potencia instalada era de 382.2 MW, lo que supone un aumento aproximadamente del 100 %. La potencia de los proyectos en construcción avanzada también aumenta en este periodo temporal, siendo de 717.5 MW en 2010 y 881 MW en 2011, es decir, un aumento del 23 %. Finalmente, la potencia en proyectos preasignados se ha visto reducido en un 40 %, pasando de 1374.2 MW a 842 MW instalados.

Este análisis se podría justificar fácilmente debido a la situación económica que atraviesa actualmente el país. El número de proyectos preasignados se ha visto fuertemente disminuido por la falta de medios, mientras que la potencia instalada aumenta al ir finalizándose los proyectos que ya estaban en construcción.

LOCALIZACIÓN DE CENTRALES TERMOSOLARES EN ESPAÑA

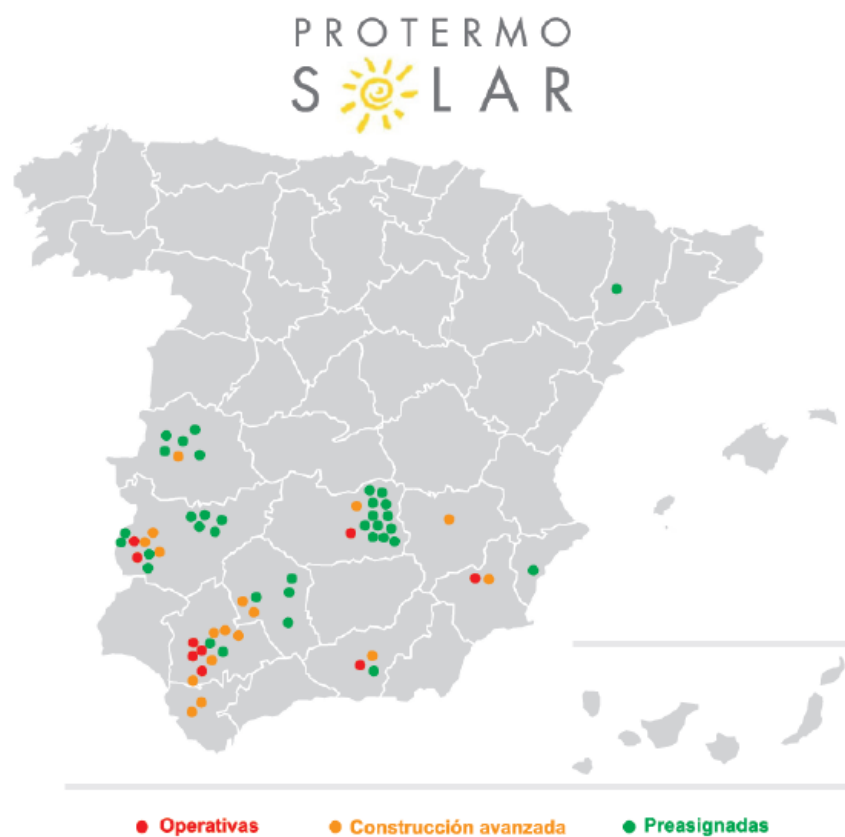


Figura 2.9: Situación de las distintas centrales termosolares en España.

Parametrización de una red neuronal para la mejora de la predicción de la Irradiancia Directa Normal

	Nombre de la Central Solar Termoelectrica	Potencia	Provincia	Tecnología
OPERATIVAS	PS10	11	Sevilla	Receptor central
	ANDASOL 1	50	Granada	Canales parabólicos
	PS20	20	Sevilla	Receptor central
	PUERTOLLANO IBERSOL	50	Ciudad Real	Canales parabólicos
	PUERTO ERRADO 1	1,4	Murcia	Fresnel
	LA RÍSCA	50	Badajoz	Canales parabólicos
	ANDASOL 2	50	Granada	Canales parabólicos
	EXTRESOL 1	50	Badajoz	Canales parabólicos
	SOLNOVA 1	50	Sevilla	Canales parabólicos
	SOLNOVA 3	50	Sevilla	Canales parabólicos
	SOLNOVA 4	50	Sevilla	Canales parabólicos
	LA FLORIDA	50	Badajoz	Canales parabólicos
	MAJADAS	50	Cáceres	Canales parabólicos
	LA DEHESA	50	Badajoz	Canales parabólicos
	PALMA DEL RÍO II	50	Córdoba	Canales parabólicos
	EXTRESOL-2	50	Badajoz	Canales parabólicos
	MANCHASOL-1	50	Ciudad Real	Canales parabólicos
	GEMASOLAR	17	Sevilla	Receptor central
CONSTRUCCIÓN AVANZADA	CASA DEL ÁNGEL	1	Cuenca	Discos parabólicos
	PUERTO ERRADO 2	30	Murcia	Fresnel
	ANDASOL - 3	50	Granada	Canales parabólicos
	PALMA DEL RÍO I	50	Córdoba	Canales parabólicos
	HELIOENERGY 1	50	Sevilla	Canales parabólicos
	HELIOENERGY 2	50	Sevilla	Canales parabólicos
	LEBRIJA 1	50	Sevilla	Canales parabólicos
	TERMOSOL-50	50	Cádiz	Canales parabólicos
	ARCOSOL-50	50	Cádiz	Canales parabólicos
	ARIES Solar Termoelectrica Extremadura-2	50	Badajoz	Canales parabólicos
	ARIES Solar Termoelectrica-1A	50	Ciudad Real	Canales parabólicos
	ARIES Solar Termoelectrica-1B	50	Ciudad Real	Canales parabólicos
	SOL GUZMAN	50	Córdoba	Canales parabólicos
	HELIOS I	50	Ciudad Real	Canales parabólicos
	HELIOS II	50	Ciudad Real	Canales parabólicos
	SOLACOR I	50	Córdoba	Canales parabólicos
	SOLACOR 2	50	Córdoba	Canales parabólicos
	SOLABEN 2	50	Cáceres	Canales parabólicos
	SOLABEN 3	50	Cáceres	Canales parabólicos
PREASIGNADAS	LA AFRICANA	50	Córdoba	Canales parabólicos
	CONSOL ORELLANA	50	Badajoz	Canales parabólicos
	MORÓN	50	Sevilla	Canales parabólicos
	MANCHASOL-2	50	Ciudad Real	Canales parabólicos
	OLIVENZA 1	50	Badajoz	Canales parabólicos
	EXTRESOL-3	50	Badajoz	Canales parabólicos
	SOLABEN 1	50	Cáceres	Canales parabólicos
	TERMOSOL 1	50	Badajoz	Canales parabólicos
	TERMOSOL 2	50	Badajoz	Canales parabólicos
	BORGES	22	Lérida	Canales parabólicos
	EXTREMASOL 1	50	Badajoz	Canales parabólicos
	SOLABEN 6	50	Cáceres	Canales parabólicos
	CÁCERES	50	Cáceres	Canales parabólicos
	CASABLANCA	50	Badajoz	Canales parabólicos
	ENERSTAR VILLENA	50	Alicante	Canales parabólicos
	8MW PUERTOLLANO	8	Ciudad Real	Discos parabólicos
	10MW PUERTOLLANO	10	Ciudad Real	Discos parabólicos
	10MW PUERTOLLANO	10	Ciudad Real	Discos parabólicos
	10MW PUERTOLLANO	10	Ciudad Real	Discos parabólicos
	10MW PUERTOLLANO	10	Ciudad Real	Discos parabólicos
	14 MW PUERTOLLANO	12	Ciudad Real	Discos parabólicos
	ARENALES	50	Sevilla	Canales parabólicos
Total 60				

Figura 2.10: Listado de centrales termosolares en España actualmente operativas, en construcción y preasignadas.

CAPÍTULO 3

RADIACIÓN SOLAR

En este capítulo se tratará de realizar una descripción de la radiación solar y de conceptos muy ligados a ella para finalmente acabar adentrándose en algoritmos y modelos que han sido directamente usados en el presente proyecto.

3.1. EL SOL

El Sol constituye la principal fuente de energía de la Tierra. En concreto, el Sol radia de forma constante una potencia de $3,8 \cdot 10^{23}$ kW de los cuales $1,7 \cdot 10^{14}$ son interceptados por la Tierra. La mayor parte de esta potencia llega a la Tierra en forma de radiación. De esta radiación recibida en la superficie exterior, el 30 % se refleja al espacio, el 47 % es absorbida por la atmósfera, tierra y océanos y el 23 % restante se usa para mantener la convección atmosférica y el ciclo hidrológico. Puede ser considerado como un cuerpo negro a la temperatura de 5777 K aplicando la ley de Stefan-Boltzmann ($E = \sigma T^4$, $\sigma = 5,6687 \cdot 10^{-8} W m^{-2} K$).

3.2. ESPECTRO SOLAR

El espectro electromagnético está compuesto de las diferentes formas que presenta la energía radiante. Éste se divide también en diferentes bandas caracterizadas por sus longitudes de onda. La energía radiante se puede considerar como un haz de partículas o cuantos de energía luminosa denominados fotones que viajan describiendo un movimiento ondulatorio a la velocidad de la luz. Cada fotón posee una longitud de onda λ , y una cantidad de energía, E , que vienen relacionadas por la ecuación:

$$E = \frac{hc}{\lambda} \quad (3.1)$$

donde h es la constante de Planck, $h = 6,6 \cdot 10^{-34} J \cdot s$, y $c = 3 \cdot 10^8 m \cdot s^{-1}$.

Si examinamos en detalle el espectro solar se puede apreciar que contiene muchas rayas oscuras a pesar de que parezca continuo. Estas demuestran la formación de un *espectro de absorción* debido a que la luz blanca a alta temperatura procedente del Sol atraviesa los gases más fríos que le rodean y a los cuales cede energía de las dife-

rentes longitudes de onda que pueden absorber y emitir los átomos de la atmósfera solar.

Además, también puede observarse otras líneas debidas a la absorción producida por la atmósfera terrestre, que pueden distinguirse de las solares, porque varían la intensidad con la inclinación de los rayos solares que llegan a la Tierra, así como también depende del espesor y composición de la capa de atmósfera que ha tenido que atravesar la radiación. Este espesor depende de la altitud del lugar y del ángulo de incidencia con el que la radiación atraviesa la atmósfera. Para tener en cuenta este hecho, el espectro de la radiación solar a nivel del suelo se da referido a un factor que se denomina Masa Óptica o Masa de Aire (*Air Mass. AM*) como se puede apreciar en la figura 3.1.




Figura 3.1: Distribución espacial de la radiación solar para radiación solar extraterrestre y radiación solar AM 1.5.

En dicho gráfico, la serie roja es la radiación solar extraterrestre mientras que la azul representa la correspondiente a una Masa Óptica de 1.5. El valor de este factor es:

$$m_r = \frac{\int_0^\infty \rho ds}{\int_0^\infty \rho dz} \quad (3.2)$$

donde s es la longitud recorrida por la radiación y z =longitud recorrida por la radiación en la dirección vertical.

Es decir, suponiendo que la composición de la atmósfera es uniforme, es el cociente entre la longitud de la trayectoria que seguiría la radiación solar para llegar a un punto situado a nivel del mar cuando el Sol estuviese en el cenit, que es lo mismo que decir que el ángulo formado por la vertical y el vector solar sea 0° . Una aproximación al cálculo de este valor es aproximarlos por la secante del ángulo cenital. Así el factor AM es igual a 1 cuando está el Sol en el cenit y se está a nivel del mar, y aproximadamente 2 cuando el ángulo cenital, definido posteriormente, vale 60° , ya que la longitud de la trayectoria de la radiación solar a lo largo de la atmósfera es el doble de la que sería a nivel del mar con un ángulo cenital de 0° .




Figura 3.2: Camino óptico seguido por los rayos solares a través de la atmósfera.

En cambio, para estimarla con mayor exactitud, se usa la siguiente fórmula:

$$m_r = \frac{1}{\cos\theta_z + 0,15 (93,885 - \theta_z)^{-1,253}} \quad (3.3)$$

Para otras presiones la siguiente aproximación permite obtener la *masa de aire*, m_a :

$$m_a = m_r (p/101,325) \quad (3.4)$$

donde p es la presión atmosférica en Pa.

3.3. LA CONSTANTE SOLAR

Se conoce constante solar como el valor de la potencia recibida por unidad de área en una superficie perpendicular a la dirección de propagación de la radiación emitida por el Sol en el exterior de la atmósfera terrestre.

Se trata de una magnitud cuyo valor, a pesar de su importancia, no ha sido determinado con precisión hasta recientemente. Las medidas de la constante solar son difíciles de realizar si se efectúan desde la superficie terrestre ya que es necesario efectuar compensaciones para la absorción en distintas bandas espectrales por las sustancias que se encuentran en la atmósfera.

Hay dos valores de referencia que se vienen usando de los años setenta; uno proporcionado por la NASA y otro por el World Radiation Center (WRC). Los valores aportados fueron de $1353 \text{ W} \cdot \text{m}^{-2}$ y $1367 \text{ W} \cdot \text{m}^{-2}$ respectivamente. Este último es el más aceptado y el que será usado a lo largo de todo el proyecto.

3.4. ABSORCIÓN Y SCATTERING

La radiación solar, en su camino hacia la superficie terrestre, sufre al pasar por la atmósfera atenuación debido a procesos de *absorción* y de *difusión*.

La absorción de la radiación solar en la atmósfera, lo que conlleva a una reducción de su intensidad, es debido sobre todo al vapor de agua y dióxido de carbono en las bandas

del infrarrojo y vapor de agua en la zona ultravioleta.

La difusión de la radiación a su paso por la atmósfera, fenómeno más conocido como *scattering*, está causada por la interacción de la radiación con las moléculas del aire, agua y partículas en suspensión. El grado en que esto ocurre dependerá del número de partículas a atravesar, dependiendo también de la longitud de onda de la radiación, λ , y el diámetro medio, d , de la partícula con la que interacciona. Por ello, existen dos tipos de scattering.

- $d < \lambda/10$: conocido como scattering de *Rayleigh*. La difusión se produce con igual intensidad en el sentido de propagación de la radiación y en sentido contrario. La intensidad de la luz dispersada es inversamente proporcional a la cuarta potencia de la longitud de onda ($\propto 1/\lambda^4$). Lo producen las moléculas de gases que componen la atmósfera.
- $d > \lambda/4$: este caso se conoce como *scattering de Mie*. La luz solar no se separa en las distintas longitudes de onda y todas las longitudes de onda son difundidas. Lo forman primordialmente el vapor de agua y aerosoles en la atmósfera.

Por estos fenómenos la atmósfera se percibe como se conoce. Es decir, el cielo es azul porque las moléculas de la atmósfera favorecen las longitudes de onda corta. En cambio, las nubes, al estar formadas por partículas en suspensión de gran tamaño, se produce el efecto de Mie, y por ello las nubes poco espesas se perciben como blancas y no azules. Por otra parte, es muy común en un día soleado encontrar en el horizonte un fondo blanquecino.




Figura 3.3: Fenómeno de scattering por Rayleigh o por Mie según incidencia del sol.

3.5. TRANSMITANCIA

Un concepto relacionado a los de absorción y scattering es el de transmitancia. Es conveniente definir este concepto dado que se ha usado constantemente más adelante. La transmitancia será la fracción de radiación incidente que atravesará un cuerpo respecto de la inicial. Es decir:

$$\tau = \frac{I}{I_o} \quad (3.5)$$

3.6. DISTANCIA SOL-TIERRA

Como bien es sabido, la órbita de la Tierra alrededor del Sol es elíptica, estando el Sol posicionado en uno de los focos. Es de importancia conocer con precisión la distancia del Sol a la Tierra ya que el valor de la radiación solar recibida depende en proporción inversa del cuadrado de su distancia.

La distancia media del Sol a la Tierra se ha estimado en $1,496 \cdot 10^8 km$. A esta distancia se le llama Unidad Astronómica (UA). La Tierra se encuentra en su posición más próxima al Sol (perihelio) aproximadamente el día 3 de Enero. Esta distancia es 0.983 UA. En el punto más lejano (afelio) se encuentra aproximadamente el día 4 de Julio, siendo la distancia correspondiente de 1.017 UA.




Figura 3.4: Eclíptica con indicaciones de las posiciones de la Tierra más relevantes a lo largo del año.

A lo largo de los años han sido desarrollados diferentes ecuaciones para estimar dicha distancia con alto grado de exactitud. La más famosa y utilizada es la ecuación de

Spencer:

$$S = 1,00011 + 0,034221\cos\Gamma + 0,00128\sin\Gamma + 0,000719\cos\Gamma + 0,000077\sin2\Gamma \quad (3.6)$$

donde Γ expresado en radianes se conoce como el ángulo diario que es:

$$\Gamma = \frac{2\pi(d_n - 1)}{365} \quad (3.7)$$

donde d_n es el número de día del año de 1 a 365, sin tener en cuenta el día de más en años bisiestos.




Figura 3.5: Distancia Sol-Tierra frente a día del año.

3.7. ECUACIÓN DEL TIEMPO

El tiempo solar es definido en función de la rotación de la Tierra alrededor del Sol y de su eje polar. Un día solar se define como el intervalo de tiempo entre dos pasos sucesivos del Sol por el meridiano del observador.

Los días solares varían a lo largo del año, siendo dos los factores causantes de ello;

- La inclinación de la Tierra con respecto a la Eclíptica, que es el plano definido por la trayectoria de la Tierra alrededor del Sol.
- La órbita elíptica de la Tierra.

La ecuación del tiempo viene dada por la diferencia entre el movimiento real de la Tierra y si éste fuera uniforme. Dada la similitud a un comportamiento senoidal, esta puede ser expresada en términos de series de Fourier de la forma:

$$Et = 229,18 (0,000075 + 0,001868\cos\Gamma - 0,032077\sin\Gamma - 0,014615\cos2\Gamma - 0,04089\sin2\Gamma) \quad (3.8)$$




Figura 3.6: Valor de la ecuación del tiempo a lo largo del año.

Mediante la ecuación del tiempo se consigue relacionar la hora local con la hora solar verdadera. La hora solar verdadera u hora local aparente es la que se expresa haciendo que las doce del mediodía coincidan con el paso del Sol por el meridiano del observador. Para ello se necesita conocer el meridiano estándar que determina el tiempo local en la zona. Se realizará una corrección sobre éste y se sumará la ecuación del tiempo obteniéndose la hora solar verdadera.

$$HSL = HSE + 4 (L_s - L_e) + E_t \quad (3.9)$$

Donde el 4 es debido a que si una hora corresponde a 15° entonces cada grado corresponderá a 4 minutos.

3.8. DIRECCIÓN DE LA RADIACIÓN SOLAR

Algunos de los ángulos usados para determinar la dirección de la radiación solar respecto a un plano con cualquier orientación particular relativa a la Tierra son:

- *Latitud*: es la distancia angular entre un punto de la superficie terrestre y la línea de ecuador. Al norte la latitud es positiva. Es definida entre -90° y 90° .
- *Longitud*: es la distancia angular entre un punto en la superficie terrestre y el meridiano de Greenwich. Al este es positiva. Es definida entre -180° y 180° .

- *Declinación*: como es bien sabido la Tierra se encuentra inclinada respecto de la normal al plano de su órbita. Por esta razón, la cantidad de radiación solar recibida a lo largo de un día por un punto determinado de la Tierra varía a lo largo del año dando lugar a cambios estacionales. El ángulo que forma la línea que une los centros del Sol y la Tierra con el plano ecuatorial terrestre también varía y se llama declinación. En la figura 3.4 se puede apreciar este ángulo. La declinación puede ser calculada mediante otra ecuación desarrollada por Spencer (en grados). Ésta será usada en el algoritmo de posición solar usado en el presente proyecto.

$$\delta = 0,006918 - 0,399912 \cos\Gamma + 0,0070257 \sin\Gamma - 0,006758 \cos 2\Gamma + 0,000907 \sin 2\Gamma - 0,002697 \cos 3\Gamma + 0,00148 \sin 3\Gamma \quad (3.10)$$

En los equinoccios $\delta = 0$ mientras que en el solsticio de verano y en el de invierno será $\delta = +23^\circ 27' / -23^\circ 27'$ respectivamente.

- *Ángulo cenital*: es el ángulo entre la vertical, cénit del observador, y la línea hacia el Sol, i.e, el ángulo de incidencia de la radiación solar directa en una superficie horizontal. Una ecuación muy utilizada que relaciona los ángulos cenital, declinación, latitud y ángulo horario es:

$$\cos\theta_z = \sin\delta \sin\phi + \cos\delta \cos\phi \cos\omega_s \quad (3.11)$$

Donde θ_z denota el ángulo cenital, δ la elevación, ϕ la latitud y ω_s el ángulo horario.

- *Ángulo de elevación solar*: complementario del ángulo cenital.
- *Ángulo horario*: es el desplazamiento angular del Sol al este o al oeste respecto del meridiano local debido a la rotación de la tierra sobre su eje a 15° por hora, siendo negativo por la mañana y positivo por la tarde.

$$\omega = \frac{\text{hora solar} - 12}{15^\circ} \quad (3.12)$$

- *Ángulo azimutal solar*: es el desplazamiento angular desde el sur de la proyección de la radiación incidente en el plano horizontal. Los desplazamientos al este desde el sur son negativos y al oeste desde el sur son positivos.

Todo esto puede visualizarse en la figura 3.7:




Figura 3.7: Ángulos solares respecto de un observador en el hemisferio norte.

Además, teniendo en cuenta que un colector puede ser visto como un plano no horizontal se tiene:

- *Ángulo de incidencia*: es el ángulo entre la dirección de la radiación solar incidente en una superficie y la normal a esa superficie.
- *Inclinación*: se refiere al ángulo entre el plano de la superficie considerada y la horizontal.
- *Ángulo azimutal superficial*: es la desviación de la proyección en un plano horizontal de la normal a la superficie respecto del meridiano local, con el valor cero al sur, al este negativo y al oeste positivo. Definido entre -180° y 180° .




Figura 3.8: Ángulos de inclinación e incidencia de un colector solar.

Es por esta razón que los colectores solares vengán con sistemas de seguimiento del sol, para maximizar la energía concentrada.

3.9. ALGORITMO DE POSICIÓN SOLAR

Para el cálculo de la radiación solar es necesario el uso de un algoritmo de posición del sol dado que la potencia incidente sobre una superficie será función de los ángulos explicados.

Una vez descritos los conceptos relacionados con la posición solar es posible describir el algoritmo concreto de posición solar que ha sido utilizado en el proyecto. Con el fin de explicarlo de manera esquematizada y concisa se expresará de forma enumerada.

1. Lo primero de todo es pasar la hora a GMT.
2. Se calcula la declinación.
3. Se calcula el ángulo horario ω para una hora solar dada.
4. Se calcula el ángulo horario para la salida y puesta de Sol, ω_s , con el objeto de determinar la hora solar a la que sale, T_{sr} , y se pone, T_{ss} , el Sol en el día elegido, es decir, las horas de exposición solar. Éstas vienen dadas en función del mediodía solar, que ha sido denotado como MS . El mediodía solar será calculado en tiempo solar verdadero siendo su valor:

$$MS = 12 - \frac{E_t}{60} - \frac{4(L - Lref)}{60} \quad (3.13)$$

donde E_t es la ecuación del tiempo y L la longitud. El valor de $Lref$ es de 15° dado que el lugar está en GMT+1.

Ahora para el cálculo de T_{sr} y T_{ss} se impondrá un ángulo cenital nulo en la ecuación 3.11 y se despejará el ángulo horario deseado:

$$\cos \omega_s = \frac{-\sin \delta \sin \phi}{\cos \delta \cos \phi} = -\tan \delta \tan \phi \quad (3.14)$$

$$T_{sr} = MS - \frac{\omega_s}{15} \frac{180}{\pi} \quad (3.15)$$

$$T_{ss} = MS + \frac{\omega_s}{15} \frac{180}{\pi} \quad (3.16)$$

5. El ángulo de elevación se calculará mediante la ecuación 3.11. Éste será truncado para ángulos menores de 5° donde tomará valor 0.

6. Para el cálculo del azimut se calculan las coordenadas del vector solar U_{sx} , U_{sy} y en función de la latitud, la declinación y del ángulo horario.

$$U_{sy} = -\cos\delta \sin\phi \cos\omega + \sin\delta \cos\phi \quad (3.17)$$

$$U_{sx} = \cos\delta \sin\omega \quad (3.18)$$

El azimut se obtendrá como el arcotangente del cociente de la coordenada x e y, limitándolo a 0 para ángulos de elevación menores que 0.

3.10. COMPONENTES DE LA RADIACIÓN SOLAR

Debido a las interacciones que la radiación solar sufre con las partículas y sustancias que componen la atmósfera y la posición del Sol, se puede hablar de tres componentes.

Por una parte, la *radiación solar directa* es aquella fracción de la radiación solar que llega a la superficie terrestre con una trayectoria bien definida hasta la posición determinada. Debido a ello, puede ser concentrada por reflexión. En días soleados en ambientes despejados puede llegar al 90 % de la radiación global; en cambio en días cubiertos el valor puede descender hasta valores próximos a cero.

Es la componente perpendicular a un plano respecto de una superficie de captación. Por tanto esta magnitud deberá ir multiplicada por el coseno del ángulo que forma la dirección del rayo incidente sobre dicha superficie.

Por otra parte, como ya ha sido indicado, parte de la radiación solar a su paso por la atmósfera se pierde al ser absorbida por las sustancias de la atmósfera. Esto provoca cambios de dirección en la radiación y una disminución de la energía. La fracción de la radiación solar que llega a la superficie terrestre sin una trayectoria definida se denomina *radiación solar difusa*. Esta componente de la radiación solar global se puede descomponer a su vez en tres componentes:

- *Circumsolar*: la componenete que llega de la zona brillante alrededor del disco solar.
- *Banda del horizonte*: la componente que proviene de la zona sobre el horizonte.
- Componente correspondiente al resto de la bóveda celeste.

Al igual que la radiación solar directa, esta componente puede variar enormemente, de forma complementaria a la directa, tomando valores elevados en condiciones de cielo cubierto y valores pequeños cuando no.

Finalmente, la *radiación reflejada*, la cual también es denominada albedo, es la radiación que llega a una superficie determinada como consecuencia de la reflexión de la radiación solar en el suelo o en superficies verticales. Esta es una proporción pequeña con respecto a las otras dos.




Figura 3.9: Esquema de las componentes de la radiación.

La relación entre las componentes respecto de una superficie de captación quedará:

$$I_G = I_b \cos \theta + I_D \quad (3.19)$$

siendo θ el ángulo de incidencia. Cada uno de estos términos representa irradiancia. Este término es utilizado para describir la potencia incidente por unidad de superficie de la radiación. Ampliamente es denotada la irradiancia solar directa como *DNI* (*Direct Normal Irradiance*); I_D también es conocida como *DHI* (*Diffuse Horizontal Irradiance*), es decir, la componente difusa; I_G también es denotada como *GHI* (*Global Horizontal Irradiance*).

3.11. IMPORTANCIA DE LA ESTIMACIÓN DE LA RADIACIÓN SOLAR DIRECTA PARA APLICACIONES DE CONCENTRACIÓN SOLAR

Es de suma importancia conocer la disponibilidad energética del recurso solar en un emplazamiento a la hora de elegirlo para la construcción de una instalación termosolar. Es fundamental conocer cuánto y cómo voy a obtener el recurso para posteriormente poder realizar el diseño. En concreto, el valor de la radiación solar directa para aplicaciones de concentración, dado que es la única que puede ser acumulada. Lo ideal es tener una base de datos amplia de la ubicación. Sin embargo, esto no es fácil; la radiación solar directa es algo compleja de medir y costosa. Por ello se ha de recurrir a diferentes modelos para estimarla a partir de otras variables meteorológicas. A continuación se han detallado los sistemas de medida actualmente más utilizados para posteriormente explicar modelos para la estimación de DNI.

3.12. INSTRUMENTOS DE MEDIDA DE RADIACIÓN SOLAR Y OTRAS VARIABLES

La radiación solar generalmente es medida en estaciones meteorológicas. También en ellas se miden otras variables meteorológicas de interés como el viento, la humedad

relativa, la precipitación, la temperatura y/o la presión atmosférica. Mediante el estudio de estas variables es posible establecer el comportamiento atmosférico de la zona donde se encuentra la estación.



Figura 3.10: Estación meteorológica típica.

Existen infinitud de diferentes tipos de sensores en la industria para la obtención de la medida de las variables meteorológicas. Por ello, dado que no es el objeto de este proyecto se va a realizar una simple enumeración de los sensores que suelen formar parte de las estaciones meteorológicas. Posteriormente se explicará al lector con más detalle los instrumentos más usados en relación con la radiación solar.

- *Termómetro*, medida de temperaturas. Generalmente el sensor se trata de un termistor. Su funcionamiento se basa en la variación de la resistividad que presenta un semiconductor metálico con la temperatura.
- *Barómetro*: medida de presión atmosférica en superficie.
- *Pluviómetro*: medida de la cantidad de precipitación.
- *Psicrómetro o higrómetro*: medida de la humedad relativa del aire y la temperatura del punto de rocío.
- *Anemómetro*: medida de la velocidad del viento y veleta para registrar su dirección. Suele ser medido a una altura de 10 m.
- *Veleta*: indica la dirección del viento.

3.12.1. DATALOGGER

El datalogger se trata de un dispositivo electrónico encargado de registrar datos en el tiempo de sensores externos a él o propios. Éstos se pueden conectar a un ordenador

personal y mediante un software específico permiten ver y analizar los datos que han sido registrados. Permiten recoger automáticamente datos, dejándolos sin vigilancia para registrar los datos durante todo el período de seguimiento.

3.12.2. INSTRUMENTOS DE MEDIDA DE LA RADIACIÓN SOLAR

La radiación solar puede ser medida de diferentes formas. Se puede medir global, directa o difusa. La radiación global es la radiación hemiesférica, i.e, la radiación recibida por una superficie plana a través de un ángulo sólido de 2π esterorradianes siendo un esterorradián el equivalente tridimensional del radián. Así, una esfera tendrá un ángulo sólido de 4π esterorradianes. Los instrumentos que miden radiación solar hemiesférica son denominados piranómetros.




Figura 3.11: Fotografía de un piranómetro con y sin rotating shadowband.

La radiación global es medida por un piranómetro. Si lo que se desea es obtener la difusa o directa lo que se hace es añadirle un *rotating shadowband*. Esto es una banda que protege a la hemiesfera de recibir radiación directa del sol. Éste puede ser en vez de una banda un disco completo. Tienen que ser programados para realizar un seguimiento del sol. Por ello, requiere mucho mantenimiento. Como el anillo cubre también partes del cielo difuso, se tiene que aplicar una corrección a los valores obtenidos. Este factor de corrección dependerá del tipo de piranómetro, la geometría del anillo o del shadowband, la latitud del emplazamiento e incluso la anisotropía del cielo despejado.

También la radiación directa puede ser medida mediante un instrumento en forma de tubo que apunta al sol. Dicho instrumento se llama pirheliómetro. Éste es más preciso pero a la vez requiere de una mayor atención.



Figura 3.12: Fotografía de un pirheliómetro.

Este tipo de instrumento suele tener un campo de visión limitado a 5° de apertura.




Figura 3.13: Ángulo de apertura de un pirheliómetro.

Otra forma alternativa de medir la radiación difusa es usando simultáneamente un piranómetro y un pirheliómetro. De esta manera, se consigue medir la radiación difusa y la directa será por ende la diferencia de las dos, corregido por el coseno del ángulo cenital del Sol. El detector de la radiación está situado horizontalmente.

Estos tipos de instrumentos existen en diferentes clases según precisión, encontrando un error en esta industria que puede llegar a variar entre el $\pm 0,5\%$ que son los instrumentos de referencia a un error aproximado de $\pm 10\%$.

El principio de funcionamiento de todos ellos está basado en el uso de termopilas, haciendo uso del efecto Seebeck, el cual se refiere a la emisión de electricidad en un circuito eléctrico compuesto por conductores diferentes, mientras estos tienen diferentes temperaturas. La superficie del piranómetro está pintada de negro y a ella va adherida un termopar. El termopar de referencia estará ubicado en contacto con la superficie del instrumento. La diferencia de ambas temperaturas producirá una diferencia de voltaje que será proporcional a la radiación incidente. Dicha diferencia de voltaje suele ser muy pequeña por lo que debe ser amplificada.

Ambos instrumentos tienen un material de filtrado que es cristal. Éste solo permite pasar la radiación de longitud de onda comprendida en el rango $0,3 - 3\mu m$. Una de sus funciones es proteger de efectos externos y aislar la temperatura de referencia de tal

manera que no dependa de fenómenos meteorológicos como el viento, aumentando las pérdidas.

3.12.3. HELIÓGRAFO

Otro instrumento usado relacionado con la radiación solar es el heliógrafo. En concreto éste contabiliza las horas de sol a lo largo de un día en un determinado lugar. Esto puede ser de utilidad para la elaboración de modelos de cielo, como se verá más adelante.

Consiste básicamente en una bola de vidrio que a modo de lente concentra los rayos solares en un foco próximo a ella. Según el Sol se va moviendo, este foco va recorriendo una banda o cartulina fijada detrás de la bola. La concentración del foco va quemando dicha cartulina cuando los rayos solares son intensos. Si la formación del foco fuera hecha a través de una lupa sería necesario desplazar ésta constantemente en función de las variaciones diurnas y estacionales de la posición del sol. Para evitar éste inconveniente una esfera de vidrio es utilizada.



Figura 3.14: Heliógrafo.

En las bandas vienen marcadas las horas y las medias horas del día. Son tiras de cartulina de buena calidad que no se dilatan por efecto de la humedad. Cuando hay nubes y la intensidad de la irradiancia es menor, la quema de la cartulina no se produce. En el caso de que las nubes desaparecieran, la carbonización de la cartulina continuaría. La suma de las longitudes de los segmentos donde se ha producido carbonización de la banda serán las horas de sol que ha tenido el día.




Figura 3.15: Bandas usadas de un heliógrafo.

Según la estación del año se usarán un tipo de banda u otra. Para ello el heliógrafo lleva tres ranuras diferentes en las cuales se pueden alojar las tres clases de bandas.

- Las bandas de verano son largas y curvas. Se encajan en la ranura inferior.
- Las bandas equinocciales son rectas, para las estaciones de primavera y otoño. Se colocan en la ranura central.
- Las bandas de invierno también son curvas, pero de menor longitud que las de verano. Se encajan en la ranura superior.

Para que esté bien ajustado este instrumento es necesario que esté situado perfectamente en horizontal, tanto en el sentido Norte-Sur, como en el sentido Este-Oeste y estar orientado hacia el Sur si se encuentra en el hemisferio Norte. Además, el heliógrafo debe estar ajustado tanto para la latitud geográfica del lugar donde va a ser instalado como en longitud.

3.13. MODELOS DE CIELO DESPEJADO

Un modelo de cielo despejado consiste en una parametrización para estimar la radiación solar integrada en todo el espectro en un día completamente despejado. Generalmente se obtienen buenas estimaciones con estos modelos. En cambio, para días cubiertos o parcialmente cubiertos la estimación de la radiación solar por métodos físicos es muy compleja y no se han realizado grandes avances en este sentido, optándose por otras opciones para éste cálculo, como técnicas estadísticas.

3.14. EL MODELO METEOROLÓGICO DE RADIACIÓN (MRM)

El modelo MRM fue desarrollado con el objetivo de estimar datos de radiación solar en lugares donde no hubiera medidas [3]. Para ello, MRM emplea como entrada datos meteorológicos comunes que suelen estar más disponibles: temperatura, humedad, relativa, presión barométrica y horas de sol.

Este modelo fue originalmente desarrollado en Grecia a principios de los años 90. Dado que el planteamiento ha resultado de un gran interés por parte de los investigadores, éste ha ido evolucionando a lo largo de los años desde entonces, hasta obtenerse la versión número cinco. Una de sus particularidades es que se puede descomponer en dos submodelos: uno de cielo despejado y otro de cielo cubierto.

La versión original del MRM era eficaz para cielo despejado, no siéndolo para condiciones de nubosidad. El MRM v2 introdujo nuevas ecuaciones analíticas para las transmitancias convirtiéndose en más eficaz que su predecesor. De todas maneras, esta versión sólo funcionaba correctamente en cielo despejado. Estas deficiencias fueron resueltas mediante el desarrollo de una tercera versión (MRM v3). A lo largo de otros proyectos de investigación se desarrolló la versión 4 que proveía mejoras en condiciones de nubosidad. Tras diversos estudios en diferentes universidades, se detectaron y corrigieron errores en las ecuaciones de la transmitancia y de la geometría solar, dando lugar a la última versión (MRM v5).

A lo largo de la realización del presente proyecto se ha utilizado el modelo MRM v5, con la salvedad de que ciertas modificaciones le han sido realizadas. A continuación se ha procedido a explicar en que consiste este algoritmo, mostrando sus ecuaciones y explicando cómo ha sido manipulado.

3.14.1. MODELO DE CIELO DESPEJADO

La irradiación directa sobre superficie horizontal bajo cielo despejado se estima a partir de la transmitancia directa de los distintos procesos de absorción y dispersión de la radiación solar en la atmósfera.

$$I_b = I_{ex} \sin h T_r T_o T_w T_{mg} T_a \quad (3.20)$$

T_r es la transmitancia óptica a través de las moléculas debido a la dispersión de Rayleigh; T_o la transmitancia óptica a través del ozono; T_w la transmitancia óptica debido a la absorción del vapor de agua; T_{mg} la transmitancia óptica debido a la absorción de gases mezclados (CO_2 , CO , N_2O , CH_4 y O_2) y T_a es la transmitancia óptica debido a aerosoles a causa de la dispersión de Mie.

Las distintas funciones de transmisión atmosférica se determinan por medio de expresiones paramétricas que son función principalmente de la masa de aire, del contenido de los distintos absorbentes atmosféricos, de la temperatura y humedad relativa y del parámetro de turbiedad de Angstrom. Su cálculo se expone a continuación:

- T_r . La función de transmitancia por difusión es:

$$T_r = \exp [-0,1128 m'^{0,8346} (0,9341 - m'^{0,9868} + 0,9391 m')] \quad (3.21)$$

donde la m' es la masa de aire corregida por presión, ya explicada anteriormente.

- T_o . La transmitancia óptica debido a la absorción por ozono es:

$$T_o = 1 - [0,1611 x_o (1 + 139,48 x_o)^{-0,3035} - 0,002715 x_o (1 + 0,00440 x_o + 0,0003 x_o^2)^{-1}] \quad (3.22)$$

donde $x_o = l_o m$ y l_o es la cantidad total de una columna de ozono en la atmósfera. Este término se refiere a cuantas moléculas de ozono hay en el aire sobre cierto punto en la tierra y esta unidad suele venir dada en unidades Dobson. Si se trajera la capa de ozono a la superficie de la Tierra a temperatura y presión estándar, ésta mediría 3 mm de espesor. A este valor se le asignó el valor de 300 UD (unidades Dobson), que corresponde, aproximadamente, al promedio global de la columna de ozono.




Figura 3.16: Columna de ozono.

Una aproximación de este valor es:

$$l_o = d_1 + \{d_2 + d_3 \sin[d_4(d_n - 30)] + d_5 \sin[d_6(\theta + \Delta)]\}[\sin^2(d_7\phi)] \quad (3.23)$$

donde $d_1 = 0,235$, $d_2 = 0,150$, $d_3 = 0,040$, $d_4 = 0,9865$, $d_5 = 0,020$, $d_6 = \pi^2/10800$ y $d_7 = 1,28 \pi/180$. En la ecuación 3.23, θ es la longitud geográfica en grados, positiva hacia el este de Greenwich, ϕ es la latitud geográfica, en grados, positiva en el Hemisferio Norte; Δ es un factor de corrección tomando un valor de 20° para el Este o 0° para el Oeste.

- T_w . La transmitancia óptica debido a la absorción por vapor de agua es:

$$T_w = 1 - 2,4959 x_w [(1 + 79,034 x_w)^{0,6828} + 6,385 x_w]^{-1} \quad (3.24)$$

donde $x_w = l_w / m$ y l_w es la columna total de agua precipitable, en cm. Puede ser aproximada por:

$$l_w = 0,23 e_m 10^{-H/22000} \quad (3.25)$$

donde e_m es la presión parcial de vapor de agua en mmHg a la altura de la estación H (en metros).

- T_{mg} . La transmitancia óptica causada por la mezcla de diferentes gases en la atmósfera se puede calcular como el producto de las transmitancias de los diferentes gases (H_2O , O_3 , CO_2 , CO , N_2O , CH_4 y O_2).

$$T_{mg} = T_{CO_2} T_{CO} T_{N_2O} T_{CH_4} T_{O_2} \quad (3.26)$$

La función de transmitancia para cada gas es genérica, cambiando solamente el valor de los coeficientes.

$$T_i = 1 - [A' m l_i / (1 + B' m l_i)^{C'} + D' m l_i] \quad (3.27)$$

Tabla 3.1: Valores de los coeficientes A', B', C' y D'.

Gas	A'	B'	C'	D'
H_2O	3.0140	119.300	0.6440	5.8140
O_3	0.2554	6107.260	0.2040	0.4710
CO_2	0.7210	377.890	0.5855	3.1709
CO	0.0062	243.67	0.4246	1.7222
N_2O	0.0326	107.413	0.5501	0.9093
CH_4	0.0192	166.095	0.4221	0.7186
O_2	0.0003	476.934	0.4892	0.1261

donde l_i es la columna vertical para cada uno de los gases. Los valores de los coeficientes vienen dados en la 7.5. Los l_i s son usados en las expresiones analíticas de las correspondientes funciones de transmitancia.

- T_a . La función de transmitancia de Mie es:

$$T_a = \exp[-m \beta [0,6777 + 0,1464 \beta - 0,00626 (m \beta)^2]^{-1,3}] \quad (3.28)$$

donde β es el el parámetro de turbidez de Angstrom. Dada su relevancia se explicará más adelante este parámetro con más detalle.

La obtención del valor de la irradiancia difusa, I_d , se realizará de forma análoga a la de la directa, es decir, multiplicando por una serie de descuentos que serán las funciones de transmitancia.

$$I_{ds} = I_{ex} \cos \theta T_{aa} T_o T_w T_{mg} 0,5 (1 - T_{as} T_r) \quad (3.29a)$$

$$I_{dm} = (I_b + I_{ds})[\rho_g \rho_a / (1 - \rho_g \rho_a)] \quad (3.29b)$$

$$I_d = I_{ds} + I_{dm} \quad (3.29c)$$

donde I_{ds} es la radiación difusa circunsolar producida por dispersión de moléculas y aerosoles e I_{dm} la componente difusa reflejada por el terreno y vuelta a reflejar por la atmósfera, ρ_a es el albedo de la atmósfera y ρ_g es el albedo del terreno.

$$\rho_a = 0,0685 + 0,16(1 - T_{a1,66}) \quad (3.30)$$

donde $T_{a1,66}$ implica el valor de T_a con $m=1.66$ (o $\theta_z = 53^\circ$).

La función de absorción de aeerosoles, T_{aa} es:

$$T_{aa} = 1 - 0,1(1 - m + m^{1,06})(1 - T_a) \quad (3.31)$$

La expresión para la dispersión por aerosoles, T_{as} es:

$$T_{as} = T_a / T_{aa} \quad (3.32)$$

La irradiancia global horizontal viene entonces dada por:

$$I_g = I_b + I_d \quad (3.33)$$

Tabla 3.2: Valores típicos para el parámetro K para diferentes latitudes en el Hemisferio Norte.

K	ϕ (grados)
0.32	30
0.32	35
0.33	40
0.34	45

3.14.2. MODELO DE CIELO CUBIERTO

En el modelo MRM la radiación directa para cielo cubierto se estima a partir de un factor de transmitancia nubosa T_c .

$$I'_b = I_b T_c \quad (3.34)$$

Este factor puede ser calculado mediante el cociente entre el número de horas de tiempo de luz medido en un día y el máximo astronómico calculado teóricamente.

$$T_c = k (SD_m/SD_t) \quad (3.35)$$

Donde k es un coeficiente empírico para la nubosidad, cuyo valor suele estar entre 0.75 y 1. Suele ser habitual el caso en que $k = 1$.

La componente difusa (I'_d) y global (I'_g) vienen dadas entonces por:

$$I'_{ds} = I_{ds} T_c + K [1 - T_c](I_b + I_{ds}) \quad (3.36a)$$

$$I'_{dm} = (I'_b + I'_{ds})[\rho_g \rho'_a / (1 - \rho_g \rho'_a)] \quad (3.36b)$$

$$I'_d = I'_{ds} + I'_{dm} \quad (3.36c)$$

$$I'_g = I'_b + I'_d \quad (3.36d)$$

$$\rho'_a = 0,0685 + 0,16(1 - T_{a1,66} + V(1 - SD_m/SD_t)) \quad (3.36e)$$

donde ρ'_a es el albedo de cielo cubierto, K un coeficiente empírico dado en la tabla 3.2, para diferentes latitudes geográficas y V es un parámetro que varía en el rango 0.3 - 0.6.

3.15. AEROSOL

Los aerosoles son una componente fundamental de la química atmosférica y de los balances de la radiación, siendo un aerosol una mezcla heterogénea de partículas sólidas o líquidas suspendidas en un gas. A continuación se han explicado los parámetros ópticos que caracterizan a un aerosol para posteriormente describir brevemente una base de datos para la obtención de dichos valores.

Tabla 3.3: Valores representativos del parámetro β bajo diferentes condiciones atmosféricas, añadiendo diferentes rangos de visibilidad, V .

Condiciones atmosféricas	β	V [km]
Limpia	0.05	340
Clara	0.1	340
Turbia	0.2	11
Muy turbia	0.4-0.5	≤ 5

3.15.1. PARÁMETRO DE TURBIDEZ

La ecuación de Angstrom viene dada por la expresión:

$$\delta_{a,\lambda} = \beta \lambda^{-\alpha} \quad (3.37)$$

Donde $\delta_{a,\lambda}$ es el llamado espesor óptico de los aerosoles, que expresa la cantidad de luz que ha sido absorbida o dispersada durante el camino de la luz a través de un medio. En el caso de la atmósfera este valor irá mutliplicado por la masa óptica. Así, si se tiene una intensidad de la radiación I_o al inicio y I al final estas se relacionan mediante la ecuación:

$$I = I_o e^{-m \tau} \quad (3.38)$$

Volviendo a la ecuación 3.37, β es conocido como el coeficiente de turbidez y α es un parámetro relacionado con el tamaño de partícula de los aerosoles, y es también conocido como exponenete de Angstrom. Es difícil conocer estos parámetros para la mayoría de localidades: se han realizado diversidad de estudios que dan un valor aproximado de estos coeficientes según el tipo de área. Por ello, es frecuente utilizar una expresión que relaciona β con la latitud geográfica ϕ y la altitud de la estación, H . La expresión es:

$$\beta = \beta' + \Delta\beta \quad (3.39a)$$

$$\beta' = (0,025 + 0,1 \cos \phi) e^{-(0,7H / 1000)} \quad (3.39b)$$

$$\Delta\beta = \pm(0,02 - 0,06) \quad (3.39c)$$

donde β' representa el valor anual medio de la turbidez y $\Delta\beta$ la desviación estacional respecto de la media, i.e, valores bajos en invierno, valores altos en verano. β está en el rango de 0.05-0.4 para un rango de concentración de aerosoles desde bajo hasta alto. Algunos valores representativos de β vienen dados en la tabla 3.3. Además de esto, existen correlaciones de estos parámetros con la visibilidad medida de un lugar.

$$\beta = 0,55^\alpha (3,912/V - 0,02262)[0,02472 (V - 5) + 1,132] \quad (3.40)$$

donde V es la visibilidad horizontal en km. Esta se define como la distancia horizontal máxima a la que un observador puede distinguir claramente algunos objetos de referencia en el horizonte.

Un valor típico y el más usado para α es 1.3.

3.15.2. GLOBAEROSOL

Es muy importante el conocimiento de la distribución de aerosoles en el estudio climático del planeta y predicción del tiempo, además de que es muy importante el conocimiento de la materia particulada para evitar problemas de salud actuales y futuros en grandes focos de contaminación. Todo esto hace que se tenga especial interés en el desarrollo de este área de conocimiento hasta ahora desconocida. Por esta razón ha surgido el proyecto GLOBAEROSOL (www.globaerosol.info). La idea era realizar un proyecto que no solo sirviera para ámbitos de investigación o comercial si no para ambos, analizando los requerimientos de cada parte, ciencia e industria. En concreto de aquí se puede obtener el exponente de Angstrom y los espesores ópticos para dos diferentes longitudes de onda: 550 y 870 nm.

3.16. MODIFICACIONES DEL MRM

En la sección 3.14 se ha explicado el modelo MRM que es el que se usará para el desarrollo del proyecto. Como se ha visto, éste tiene como entradas las principales variables meteorológicas presión, humedad relativa y temperatura; por otro lado tiene otras entradas relacionadas con la geometría solar como el ángulo de elevación, el día del año y la altura del emplazamiento. Finalmente, tiene una entrada que es el dato de horas de luz solar medidas a lo largo de un día. Como ya se vio en la sección 3.12.3 esto es medido mediante un heliógrafo. Esta entrada se metió con el fin de emular el efecto de la nubosidad. En cambio, los resultados distaban mucho de la realidad. Lo único que se conseguía era obtener un perfil de radiación solar en día despejado de forma atenuada.

La principal modificación realizada ha sido en el parámetro de las horas de luz diarias. Se cambió éste por un índice de nubosidad estimado a partir de modelos numéricos de predicción lo cual mejora razonablemente los resultados obtenidos. El cómo obtener dicho índice se indicará en el próximo capítulo, una vez que el lector conozca los modelos numéricos de predicción.

La otra modificación realizada ya ha sido explicada en la sección 3.15. En la versión 5 original del MRM para el cálculo del parámetro de turbidez de Angstrom se usaban las ecuaciones 3.39a, 3.39b y 3.39c. Dicha ecuación daba unos valores poco representativos de la zona por lo que en la versión empleada en el presente proyecto se optó por seleccionar datos reales de la base de datos *Globaerosol*. Estos datos son obtenidos a partir de un satélite no geoestacionario. Ofrece un dato horario para diferentes puntos de diferentes latitudes. En cambio, dichos puntos no son siempre los mismos por lo que se pueden obtener tan sólo 4 o 5 valores en un mes para una misma ubicación. Se trabajará introduciendo valores mensuales, que serán la media de los valores obtenidos a lo largo de los 5 años en que hay datos disponibles: 2003, 2004, 2005, 2006 y 2007.

CAPÍTULO 4

MODELOS NUMÉRICOS DE PREDICCIÓN METEOROLÓGICA

Cuando no se dispone de datos medidos, una de las metodologías para estimar ciertas variables es la utilización de modelos numéricos de predicción. Estos modelos están concebidos no sólo para la predicción meteorológica a futuro sino también para la simulación de eventos meteorológicos pasados.

A continuación se introducirá al lector en una breve descripción de las ecuaciones que gobiernan la dinámica atmosférica con el único fin de ofrecer una visión global sobre la complejidad de dichos modelos numéricos [4]. Posteriormente se ha procedido a explicar al lector cómo realizan la integración de las ecuaciones dichos modelos. Finalmente, se ha descrito qué tipo de modelos existen actualmente centrándose en los modelos usados para la realización del proyecto: *GFS* y *WRF*

4.1. LAS ECUACIONES DE LA ATMÓSFERA

Desde un punto de vista físico, la atmósfera puede ser considerada como una mezcla de gases y agua en sus distintos estados. Esta mezcla está en movimiento dentro de un campo gravitatorio sobre una esfera en rotación y calentada por el Sol. En este sistema se deben cumplir la ecuación de estado de los gases y las leyes de conservación de energía, masa y momento. Las ecuaciones vendrán dadas en parte por derivadas totales respecto al tiempo de ciertas variables físicas. En muchas de ellas se procederá de la siguiente manera. Por ejemplo, considerando el campo de velocidades $\mathbf{V}=(u,v,w)$ se tendrá:

$$\frac{df}{dt} = \frac{\partial f}{\partial t} + \frac{\partial f}{\partial x} \frac{dx}{dt} + \frac{\partial f}{\partial y} \frac{dy}{dt} + \frac{\partial f}{\partial z} \frac{dz}{dt} = \frac{\partial f}{\partial t} + \mathbf{v} \cdot \nabla f \quad (4.1)$$

donde $f=f(x, y, z, t)$. Esta ecuación indica que la derivada total en el tiempo de una función, viene dada por la derivada local en el tiempo más los cambios debidos al término de advección.

- *Ecuación de conservación de masa*: la variación total en el tiempo de la masa de una parcela de aire es nula ($dM/dt = 0$). La masa de aire contenida en un volumen $\Delta x \Delta y \Delta z$ es:

$$M = \rho \Delta x \Delta y \Delta z \quad (4.2)$$

donde ρ es la densidad del aire. Considerando la ecuación:

$$\frac{1}{M} \frac{dM}{dt} = 0 \quad (4.3)$$

De sustituir 4.2 en la ecuación 4.3 y realizar una descomposición tal como en 4.1 se obtiene:

$$\frac{1}{\rho} \frac{d\rho}{dt} + \nabla \cdot v = 0 \quad (4.4)$$

porque

$$\frac{\partial u}{\partial x} = \frac{1}{\Delta} \frac{d\Delta x}{dt} \quad (4.5)$$

- *Ecuación de conservación de vapor de agua:* determina que la variación total de vapor de agua en una parcela de aire se debe exclusivamente a procesos de evaporación E y/o condensación C.

$$\frac{dq}{dt} = E - C \quad (4.6)$$

donde q es la proporción en masa de vapor de agua en la parcela de aire. De la misma forma, se podrían incluir otras ecuaciones de conservación para otros elementos como agua líquida, ozono, etc.

- *Ecuación de estado de los gases ideales:* impone la siguiente relación entre las variables de estado termodinámicas.

$$p \nu = R T \quad (4.7)$$

donde p es la presión, T la temperatura y ν es el volumen específico o la inversa de la densidad.

- *Conservación de energía:* la superficie terrestre al ser calentada por el Sol (entendiendo como tal tierra y océano) es el foco principal de calor para la atmósfera. Este calor absorbido por la atmósfera se emplea en variar su temperatura, su densidad o ambas cosas a la vez;

$$Q = C_v \frac{dT}{dt} + p \frac{d\alpha}{dt} \quad (4.8)$$

donde los coeficientes de calor específico a volumen constante (C_v) y a presión constante (C_p) se relacionan mediante $C_p = C_v + R$. Haciendo uso de la ecuación de estado se puede obtener una forma alternativa de expresar la ecuación de energía:

$$Q = C_p \frac{dT}{dt} - \nu \frac{dp}{dt} \quad (4.9)$$

- *Conservación del momento:* la aceleración sufrida por unidad de masa es por causa de cuatro fuerzas: gradiente de presión, gravedad, rozamiento y Coriolis.

$$\frac{dv}{dt} = -\alpha \nabla p - \nabla \phi + F - 2\omega \times v; \quad (4.10)$$

Estas cinco ecuaciones que han sido desarrolladas se las suele denominar ecuaciones primitivas.

La predicción numérica del tiempo meteorológico consiste en obtener el estado de la atmósfera en un tiempo futuro a partir de la condición inicial actual. Para ello es necesario tener un modelo numérico con la capacidad suficiente para integrar las ecuaciones además de incorporar los intercambios energéticos más importantes en la capa límite (i.e, turbulencia). Dada la complejidad y no linealidad de las ecuaciones primitivas se recurre a aproximaciones que simplifican la resolución y lo hacen numéricamente más estable también. La aproximación que utilizan los modelos de predicción meteorológica es la aproximación *hidrostática*. Consiste en despreciar la velocidad vertical, considerando que las ondas de los fluidos atmosféricos se propagan sólo horizontalmente.

4.2. RESOLUCIÓN NUMÉRICA DE LAS ECUACIONES

Para obtener la solución de las ecuaciones, los modelos atmosféricos de circulación utilizan técnicas numéricas que discretizan el espacio y el tiempo. En coordenadas cartesianas se considera una rejilla 4D sobre la que se aplican técnicas de elementos finitos, mientras que en coordenadas esféricas se aplican técnicas espectrales que consideran un número finito de armónicos esféricos en la descripción del sistema (para más información ver [4]). En ambos casos, la precisión del modelo depende en gran medida de la resolución espacial: en general, una resolución mayor conlleva una precisión mayor. Sin embargo, el incremento de resolución es muy costoso. Por ejemplo, duplicar la resolución en un espacio tridimensional también requiere reducir a la mitad el paso de tiempo para satisfacer las condiciones de estabilidad computacional (para más información sobre estabilidad computacional ver [16]). Así, el coste computacional de doblar la resolución crece con un factor de $2^4 = 16$ (tres dimensiones y una variable temporal). Por tanto, existe una constante necesidad de aumentar la resolución para obtener una predicción mejor y más detallada.

La predicción numérica es, en buena parte, un problema de condiciones iniciales: dada una estimación actual del estado de la atmósfera, un modelo numérico simula su evolución, para obtener una predicción en un estado futuro. Esta condición inicial se establece a partir de la interpolación sobre los puntos de rejilla del modelo de las observaciones disponibles; este proceso de obtención de la condición inicial a partir de las observaciones se denomina *asimilación*. El principal problema de este proceso es que la cantidad de datos disponibles no es suficiente para inicializar el modelo en todos sus grados de libertad. Por ejemplo, un modelo con una resolución típica de 1° de resolución horizontal y 20 niveles verticales podría tener $180 \times 360 \times 20 = 1,3 \cdot 10^6$ puntos de rejilla, en cada una de las cuales están definidas 7 variables, con lo que tendríamos aproximadamente 10^7 grados de libertad. Para un rango temporal de ± 3 horas, existen normalmente entre 10^4 y 10^5 observaciones de la atmósfera, dos órdenes de magnitud menor que el número de grados de libertad del modelo. Más aún, la distribución espacial y temporal de las observaciones no es uniforme, existiendo regiones en Eurasia y Norteamérica con muchos datos, y regiones en el Hemisferio Sur con pocos datos. Por tanto, se hace necesario usar información adicional (llamado fondo, first-guess o información a priori) para

preparar las condiciones iniciales de la predicción.

Para los modelos globales, el first-guess es la predicción del modelo a las 6 horas, x_p . Para su obtención la predicción del modelo es interpolada a los puntos de observación y si son diferentes, convertidos a variables observadas y^o (como por ejemplo radaciones recibidas por los satélites o reflectividades de los radares). El first-guess de las observaciones será por tanto $H(x_p)$. Las diferencias entre las observaciones y el first-guess $y_o - H(x_p)$ son los *incrementos observacionales* o *mejoras*, y el análisis x_o se obtiene añadiendo las mejoras al first-guess del modelo con unos pesos W que son determinados en base a las covarianzas de los errores estadísticos de la predicción y observación:

$$x_o = x_p + W [y_o - H(x_p)] \quad (4.11)$$

Todo el proceso de asimilación de datos viene esquematizado en la figura 4.1

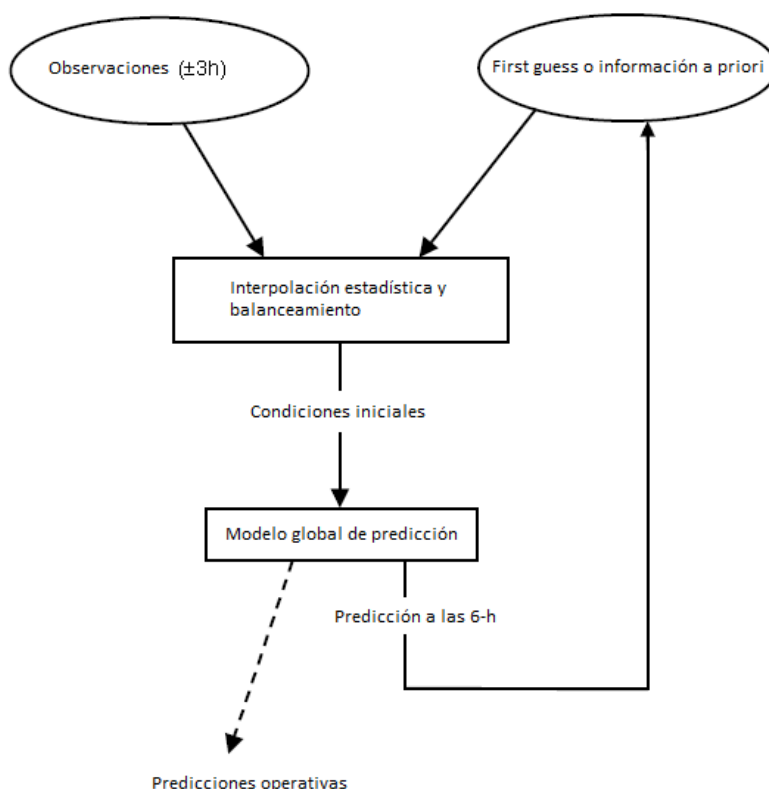


Figura 4.1: Proceso de asimilación para la obtención de las condiciones iniciales.

A pesar de que el constante incremento de la capacidad de cálculo permite integrar modelos numéricos cada vez con más resolución, existen muchos procesos atmosféricos que no pueden ser resueltos a la escala que se utiliza en los modelos. Por tanto, estos procesos no están contemplados en las ecuaciones de los modelos que se usan y se vuelven importantes en escalas espaciales pequeñas (por debajo de las decenas de km). En cambio, la exclusión de estos procesos de los modelos a gran escala puede inducir a resultados completamente diferentes en predicciones con un horizonte temporal superior

a dos días. Por esta razón, la interacción entre escalas no puede ser ignorada por los modelos y se recurre a la parametrización. Así se hace necesario añadir términos adicionales a las ecuaciones ('fuentes' y 'sumideros') para tener en cuenta estos fenómenos. Es decir, la parametrización consiste en reformular a gran escala los efectos de pequeña escala.

4.3. MODELOS GLOBALES

Los modelos globales se integran sobre todo el globo por lo que su tratamiento numérico se realiza en coordenadas esféricas. Por tanto, la resolución horizontal de estos modelos viene caracterizada por el número de modos esféricos que se consideren en el desarrollo de las soluciones de las ecuaciones diferenciales en derivadas parciales planteadas. El desarrollo de la solución en armónicos esféricos es análogo en una geometría esférica al desarrollo de series de Fourier para la solución de ecuaciones diferenciales en derivadas parciales. Este truncamiento también influirá en la resolución vertical que deberá ser consistente con la resolución espacial y temporal.




Figura 4.2: Mallado esférico en modelo global.

Dada su escasa resolución espacial, estos modelos utilizan la aproximación hidrostática de la atmósfera.

Dos de los modelos globales más usados son el IFS, *Integrated Forecast System* de ECMWF (*European Centre for Medium-Range Weather Forecasts*) y el GFS *Global Forecast System* corrido por NOAA (*National Oceanic and Atmospheric Administration*).

4.3.1. GFS

El GFS es un modelo de predicción numérica global ejecutado por NOAA. Este modelo matemático se corre cuatro veces al día: a las 00, 06, 12 y 18 GMT. Produce predicciones hasta 16 días posteriores. El modelo es corrido en dos etapas: la primera tiene una elevada resolución y finaliza a las 180 horas (7 días), siendo la resolución de 27km; la segunda parte corre desde las 180 horas hasta las 384 (16 días) en una resolución menor, de 70km. Verticalmente, divide la atmósfera en 64 capas. Realiza una predicción para cada 3 horas. Se suele aceptar que más allá de 7 días la predicción es muy general

y no muy precisa, y la mayoría de las agencias no gubernamentales rara vez usan los resultados del modelo más allá de 10 días (sobretudo porque no hay ningún otro modelo de predicción de 16 días con el que comparar).

4.4. MODELOS REGIONALES

Una solución para aumentar la resolución del modelo sin incrementar el coste computacional es considerar rejillas limitadas a zonas geográficas de especial interés. Debido a su mayor resolución, los modelos regionales tienen una mayor exactitud para reproducir fenómenos de pequeña escala como las tormentas, y también tienen mejores forzamientos orográficos que los modelos globales. A pesar de que estos modelos han utilizado históricamente la aproximación hidrostática de la atmósfera, la tendencia actual es utilizar modelos no hidrostáticos en este tipo de predicciones. Por otro lado, al no ser globales, estos modelos tienen la desventaja de que aparte de las condiciones iniciales, requieren condiciones de contorno en las fronteras del dominio. Estas condiciones de contorno necesitan ser lo más precisas posibles y por ello se toman interpolando la salida de un modelo global. Normalmente las condiciones de contorno se actualizan durante el transcurso de la predicción para imponer sobre el modelo regional la dinámica simulada por el modelo global.

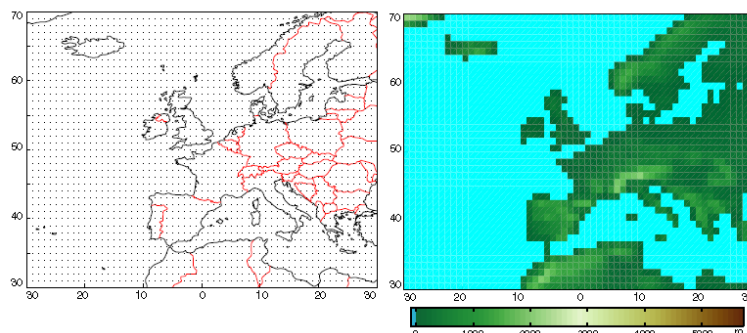


Figura 4.3: Modelo regional de Europa (izquierda) y su orografía correspondiente (derecha).

4.5. MODELOS MESOSCALARES

Más recientemente, la resolución de algunos modelos regionales ha aumentado hasta llegar a unos pocos kilómetros, con objeto de mejorar la resolución de fenómenos convectivos locales (tormentas) y otros procesos físicos de pequeña escala. Dada su escasa resolución horizontal, la formulación de estos modelos suele darse en coordenadas cartesianas y no suelen usar la aproximación hidrostática, la cual deja de tener validez para escalas horizontales menores de 10 km.

Algunos de los modelos mesoscalares más famosos son ARPS (*Advanced Regional Prediction System*), MM5 (*Penn State / NCAR Mesoscale Model, Version 5*), RSM (*NCEP Regional Spectral Model*) y el que va a ser utilizado en el presente proyecto, WRF (*Weather Research and Forecasting Model*).

4.6. WRF

El *WRF* es un modelo numérico mesoscalar diseñado tanto para predicción como para la simulación y estudio de la atmósfera. Puede ser utilizado para multitud de aplicaciones y diferentes escalas desde metros hasta cientos de kilómetros.

Está compuesto por diferentes programas:

4.6.1. WPS

El Sistema de Preprocesamiento del WRF (*WPS*) es un grupo de 3 programas cuyo objetivo en conjunto es preparar las entradas para luego ser simuladas en tiempo real en el programa *real*. Cada uno de ellos realiza una función que viene reflejada en el diagrama de flujo de datos de la figura 4.4.




Figura 4.4: Esquema del WPS.

Cada uno de los programas del WPS lee los parámetros de un archivo que tiene diferentes registros para cada uno de los programas y uno común a todos que define parámetros que son usados por más de un programa del WPS. Este archivo es *namelist.wps*.

FUNCIÓN DE CADA PROGRAMA DEL WPS

- *geogrid*: su propósito es definir los dominios de simulación e interpolar diferentes sets de datos terrestres para el mallado de los modelos. Además de computar la latitud y longitud en cada punto del mallado, geogrid interpolará categorías de suelos, categorías de uso de la tierra, elevación del terreno, temperatura media anual del suelo, fracción mensual de vegetación y albedo mensual.

- *ungrib*: su propósito es leer archivos formato GRIB y transformarlos a otro tipo de formato más simple. GRIB es el formato de archivo usado por los distintos institutos meteorológicos del mundo para almacenar información de los históricos y predicciones realizadas. En este caso los datos GRIB procederán de las salidas del GFS como ya ha sido explicado.
- *metgrid*: interpola horizontalmente los datos que han sido tratados por *ungrib* a los dominios de simulación definidos por el programa *geogrid*. La salida interpolada de *metgrid* será recibida por el programa *real*.

PARÁMETROS DEL WPS (NAMELIST.WPS)

En el anexo A se muestra el archivo del cual lee los parámetros el WPS explicándose el significado de alguno de estos parámetros y cuál han sido los valores tomados en la simulación realizada.

& SHARE

- *max_dom*: en algunos casos, se define un anidamiento de rejillas de tamaño decreciente y resolución creciente y las integraciones se realizan de forma anidada aprovechando las salidas de una rejilla como condiciones de contorno de la siguiente. Este parámetro indicará el número de anidamientos. El número elegido es 1, es decir, sin ningún anidamiento.
- *start_date* & *end_date*: indican las fechas de inicio y fin de la simulación. Las fechas elegidas de inicio son el primer instante de cada mes, siendo las de fin justo un mes posterior. Esto ha sido configurado así dado el gran coste de memoria que tiene el WRF. Cómo ha sido implementado esto para que fuera un proceso continuo se explicará en el siguiente capítulo.
- *interval_seconds*: es el tiempo cada cuánto toma unos valores para las condiciones iniciales y de contorno y proseguir con la simulación. El valor seleccionado ha sido 3600.
- *io_form_geogrid*: es el formato de archivo en el cual se escribirán los archivos creados por *geogrid*. El valor elegido fue 2, lo cual quiere decir que los archivos serán escritos en formato NetCDF(.nc).

& GEOGRID

- *dx*: especifica la resolución del mallado en la dirección según el eje x. El valor viene dado en metros. Se ha tomado 5000 como valor.
- *dy*: especifica la resolución del mallado en la dirección según el eje y. El valor viene dado en metros. Se ha tomado 5000 como valor.
- *map_proj*: designa el tipo de proyección que usa el modelo. Es decir, la topografía ha sido recreada a partir de datos de satélite y esta requiere de una corrección. El modelo que se usa para ello es el Lambertiano ('lambert').
- *ref_lat*: latitud del emplazamiento entorno al cual se quiere realizar la simulación (40.4528).

- *ref_lon*: longitud del emplazamiento entorno al cual se quiere realizar la simulación (-3.7242).
- *true_lat1*: primera latitud sobre la cual se realizará la proyección del modelo. Se ha tomado el valor de la latitud del emplazamiento más 5° (45.4528).
- *true_lat2*: segunda latitud sobre la cual se realizará la proyección del modelo. Se ha tomado el valor de la latitud del emplazamiento menos 5° (35.4528).

4.6.2. WRF

El WRF tiene dos tipos de simulaciones que puede realizar, tomando una condición ideal o una real. En el caso de este proyecto se deseaba obtener una simulación real por lo que se utilizó el programa *real*. Éste lee los datos del archivo (namelist), reserva espacio, interpola verticalmente las variables atmosféricas y chequea que todas las condiciones del suelo, como el tipo, uso, temperatura y temperatura del mar sean consistentes unas con otras.

Posteriormente se ejecuta *wrf* que es el programa encargado de la resolución numérica de las ecuaciones.

PARÁMETROS DEL WRF (NAMELIST.INPUT)

Análogamente al WPS, el WRF se controla mediante un archivo que contiene los parámetros de simulación. La mayoría de los parámetros han sido los que vienen propuestos en [7]. Dado el elevado número de parámetros, se va optar por solamente entrar a explicar los más significativos. El contenido del fichero se puede ver en el anexo B.

& SHARE

- *run_days*: tiempo de simulación en días. Se ha tomado el valor máximo por mes, es decir, 31.
- *run_hours*: tiempo de simulación en horas. Si es más de un día uno puede optar por poner 36 horas o 1 día y 12 horas. Los siguientes dos son el mismo caso pero para minutos y segundos.
- Los siguientes doce *start_* & *end_* indican la fecha de comienzo y fin de una simulación. De acuerdo con lo explicado en la sección anterior esa diferencia será de un mes.
- *interval_seconds*: tiempo cada cuanto recibe una condición de contorno.

& DOMAIN, & PHYSICS

- *time_step*: intervalo de tiempo (segundos) cada cuánto realiza la integración de las ecuaciones diferenciales. Éstas se realizan cada 30 segundos.
- *num_metgrid_levels*: número de niveles verticales en los datos de entrada. Se optó por un modelo con 27 niveles.
- *num_metgrid_soil_levels*: número de niveles de tierra del modelo de entrada. Este tiene 4 niveles a partir del año 2005.

4.6.3. NETCDF Y NCL

El formato de salida del WRF elegido es NetCDF. NetCDF (*Network Common Data Format*) fue creado como formato estándar para ser usado en algunos softwares ofrecidos a la comunidad científica. La característica de este formato es que contiene la suficiente información para poder saber qué clase de datos se encuentran en el archivo (tipo de variable, unidades, dimensiones, institución que la creó, etc) a diferencia de otros formatos que necesitan de un archivo adicional para su correcta interpretación. También se puede contar como otra de sus características la portabilidad de su formato, es decir, que puede ser manipulado por cualquier computadora que tenga las librerías NetCDF instaladas en su disco duro.

Para escribir las salidas del WRF (NetCDF) a un formato con el que se pueda trabajar (i.e, ascii) se ha usado NCL (*NCAR command language*). NCL es un lenguaje diseñado específicamente para análisis y visualización de datos científicos. Cómo ha sido implementado esto se verá en el próximo capítulo.

4.6.4. QCLOUD

Mediante el WRF se obtienen archivos en formato NetCDF que posteriormente mediante NCL serán escritos en formato ascii. Las salidas son presión, temperatura, humedad relativa, componentes del viento según el eje de coordenadas del modelo y *Qcloud*. *Qcloud* es la cantidad de vapor de agua que se puede encontrar en las nubes. Sus unidades son gramos de vapor por kilogramo de aire.

Para determinar el índice de nubosidad se establece que el umbral de qcloud a partir del cual se puede afirmar la presencia de una nube es 10^{-23} [8]. Con la configuración elegida WRF da la salida en 27 niveles de altura. Por cada punto del mallado se analizarán los 27 niveles y si en alguno de ellos se encuentra algún valor mayor que el umbral, dicho punto en el mallado tomará un valor 1. Realizando este proceso para todos los puntos finalmente se calculará un índice de nubosidad medio para toda la región de la malla.

4.6.5. VALIDACIÓN DE RESULTADOS OBTENIDOS

Finalmente, para terminar con este capítulo, esta subsección pretende mostrar al lector la fiabilidad de algunos de los valores que pueden llegar a ser obtenidos mediante el WRF. La comparación realizada ha sido con los datos medidos en una estación meteorológica en Ramgarh, India y los de un estudio de recurso solar llevado a cabo allí.

En la figura 4.5 se puede observar que la exactitud en los datos obtenidos para la presión es mayor que los obtenidos para temperatura y humedad relativa siguiendo ese orden, siendo esta última variable la que mayor error presenta.

Esta información será tenida en cuenta a la hora de seleccionar las entradas de la red neuronal.




Figura 4.5: Diagramas de dispersión de variables meteorológicas estimadas y medidas.

CAPÍTULO 5

REDES NEURONALES ARTIFICIALES

Las redes neuronales son herramientas de modelado muy usadas en nuestros días debido a su gran utilidad. La idea de investigar las redes neuronales surgió con el fin de desarrollar sistemas con capacidad de aprendizaje pero que a diferencia de los sistemas inteligentes tradicionales basados en reglas, probabilidad, etc, fueran basados en la biología.

Son herramientas capaces de capturar complejas relaciones entre entradas y salidas. Para esto a lo largo de los años se han desarrollado multitud de técnicas estadísticas. La principal ventaja de éstas frente a otros métodos se aprecia en problemas no lineales que en ocasiones vienen acompañados de una elevada dimensión; cuando es difícil entender qué es lo que realmente se está intentando de resolver. Así, es frecuente leer que una red neuronal es una *caja negra*, ya que realmente no se conoce que está ocurriendo en su interior.

Las redes neuronales han sido utilizadas ampliamente en diferentes aplicaciones tanto en ámbito militar como comercial. Por citar algunas de las comerciales:

- Medio ambiente: predicción meteorológica. Es nuestro caso en cuestión.
- Economía: previsión de los precios de mercado.
- Biología: en estudios sobre el comportamiento del cerebro humano.

En este capítulo primero se ha realizado un acercamiento al lector a las redes neuronales, de manera que conozca brevemente como se han ido desarrollando históricamente. Posteriormente se ha procedido a explicar brevemente el funcionamiento de las redes neuronales biológicas para después entrar de lleno a detallar el modelo matemático que esconde una red neuronal artificial basado en el trabajo de J.M Gutiérrez *et al.* [9].

5.1. ANTECEDENTES

La investigación de redes neuronales ha sufrido tres periodos de intensa actividad. El primer pico fue en los años 40 debido al trabajo de McCulloch y Pitts [10], en el que desarrollaron el comportamiento del cerebro humano estableciendo un modelo matemático análogo a él. En los años 60 Rosenblatt [11] desarrolló el concepto de perceptrón realizando un análisis matemático sobre su convergencia. En cambio, Minsky y Papert [12]

con su publicación en 1969 en la que realizaban una crítica sobre las limitaciones del perceptrón frenó drásticamente la investigación en este campo durante los años 70. A partir de los años 80 resurgió el interés por el estudio de redes neuronales artificiales. A partir de entonces se consiguieron ciertos hitos que afianzaron el interés por esta materia en la comunidad científica. Algunos de ellos fueron la creación de la red de Hopfield [13] y el desarrollo del algoritmo *back-propagation* para perceptrones multi-capas.

5.2. REDES NEURONALES

Mucho queda por investigar para conocer mejor el comportamiento del cerebro y sistema nervioso. La unidad fundamental es la neurona. Éstas se unen unas con otras formando redes. De hecho, el cerebro humano de media tiene unos cien mil millones de neuronas. Se componen de un núcleo, un cuerpo celular, de un axón, que es una ramificación de salida de la neurona y de un conjunto de partes filamentosas de entrada llamadas dendritas. Las neuronas transmiten información de unas a otras mediante la sinapsis. Esta es la zona de contacto entre las neuronas. La neurona trasmisora emite una señal electro-química que genera la segregación de un tipo de proteínas (neurotransmisores) que se depositan en el espacio sináptico y provocan la excitación o inhibición de la neurona contigua.




Figura 5.1: Conjunto de neuronas y sinapsis.

5.3. REDES NEURONALES ARTIFICIALES

5.3.1. ESTRUCTURA

De igual manera que la estructura del cerebro de un ser vivo, los modelos computacionales de redes neuronales están compuestos de un gran número de unidades simples de proceso (perceptrones o neuronas) conectados entre sí en base a una topología definida. Para el presente proyecto se ha utilizado una red multicapa (*feedforward*). La figura 5.2 muestra un esquema de una red neuronal de este tipo:




Figura 5.2: Esquema redes multicapa.

Las redes neuronales artificiales han de tener como mínimo una capa de entrada con tantos perceptrones en ella como entradas se quiera tener, y una capa de salida. Entre estas dos puede haber cualquier número de capas intermedias con tantos perceptrones por capa como se desee. Aquí se encuentra uno de los pequeños inconvenientes que se hallan al trabajar con redes neuronales. ¿Cuántas capas y perceptrones elegir? Se ha comprobado que en general con una o dos capas es suficiente [14]. No se obtienen mejores resultados por introducir un mayor número de capas.

5.3.2. EL PERCEPTRÓN

El perceptrón es la unidad básica de la estructura. Emula el comportamiento estímulo-respuesta de la biología: cuando el estímulo es superior a un cierto umbral entonces el perceptrón emite un impulso y si no queda en reposo. Para ello se calcula la suma ponderada de las entradas mediante unos pesos. El valor obtenido es usado como variable independiente de una función de activación para obtener el valor de salida. Esto se puede expresar matemáticamente como viene reflejado en la ecuación 5.1

$$y_i = f\left(\sum_{j=1}^n w_{ij} x_j - \theta_i\right) \quad (5.1)$$

donde $f()$ es la denominada función de activación y θ_i es el *bias* o *umbral de activación* del perceptrón.

Tal y como se ha dicho, el perceptrón está constituido en parte por una función de activación escalón. Esto puede verse como hiperplano de decisión en un espacio n-dimensional. Es decir, devolverá 1 como si la instancia está a un lado del plano y -1 si




Figura 5.3: Esquema de un perceptrón.

está en el otro (tomando 1 o -1 como posibles valores de salida) [15]. No siempre es posible separar las instancias positivas y negativas; en los casos en que sí es denominada linealmente separable.




Figura 5.4: Conjuntos separable y no separable linealmente respectivamente.

Un sólo perceptrón puede emular a muchas funciones booleanas básicas. Por ejemplo, los perceptrones pueden representar las funciones booleanas AND, OR, NAND o NOR. En cambio la función XOR (verdadera solamente si $A \neq B$) no puede ser representada por un único perceptrón [15] (ver figura 5.5).




Figura 5.5: Plano de decisión AND lógico (izquierda) y XOR lógico (derecha).

Mediante la creación de una red de perceptrones se podría representar cualquier función booleana. De hecho, esto se podría realizar sin necesitar más de dos niveles de profundidad, es decir, mediante una sola capa entre la de entrada y de salida.

5.3.3. ENTRENAMIENTO Y VALIDACIÓN

Como se ha explicado las redes neuronales aprenden a partir de un conjunto de datos de entrenamiento. El entrenamiento puede ser de dos tipos:

- *Aprendizaje supervisado*: se realiza un aprendizaje supervisado cuando están disponibles un conjunto de patrones para el entrenamiento, de tal manera que a cada entrada le corresponde una salida. El entrenamiento se basa en que la red pueda reproducir estos patrones de la manera más exacta posible. Desde un punto de vista estadístico esto se puede ver como una generalización de la regresión no lineal. En definitiva el problema se reduce a obtener los pesos apropiados utilizando algún algoritmo de aprendizaje adecuado.
- *Aprendizaje no supervisado*: en el aprendizaje no supervisado se conocen los patrones de entrada pero no los de las salidas. En consecuencia, la red se auto-organizará con el fin de hallar las salidas óptimas para cada entrada (usando algún criterio determinado como puede ser maximización de la entropía a la salida, etc). Por tanto, este tipo de redes se usa generalmente en problemas de agrupamiento, representando a cada grupo cada una de las neuronas de salida. La red distribuirá los patrones de entrenamiento entre los grupos de forma automática.

Las redes multicapa se utilizan en problemas de aprendizaje supervisado. Una vez finalizado el entrenamiento, es decir, los pesos hayan sido ya determinados, se realiza la comprobación de la calidad de este modelo. Una medida en el caso de aprendizaje supervisado es calculándose el error entre los valores objetivo y los que han sido obtenidos mediante la red. Típicamente son usados:

- La suma de los cuadrados de los errores,

$$\sum_{p=1}^a ||y_p - \hat{y}_p||^2 \quad (5.2)$$

- La raíz cuadrada del error cuadrático medio,

$$\sqrt{\sum_{p=1}^a ||y_p - \hat{y}_p||^2 / n} \quad (5.3)$$

- El error máximo,

$$\max_{p=1, \dots, a} ||y_p - \hat{y}_p|| \quad (5.4)$$

Es recomendable realizar también una *validación cruzada* para comprobar si el modelo es capaz de generalizar respecto a otras entradas que se le introduzcan. Es decir, la capacidad que tiene de reproducir nuevos patrones del problema, sin que hayan sido ya utilizados en el proceso de aprendizaje. De este modo, los datos disponibles se deberán dividir en dos conjuntos: uno destinado al entrenamiento de la red y otro a la validación. Si el error de validación fuera significativamente mayor que el error de entrenamiento, estaríamos ante un problema de *sobreajuste* durante el aprendizaje, lo que significará que el número de parámetros elegidos es excesivo. Todo esto significará que el modelo simplemente está memorizando los datos que se le han introducido.

5.3.4. REGLA DEL GRADIENTE Y REGLA DELTA

Para conseguir que este tipo de redes realicen su aprendizaje, es decir, para determinar los pesos que minimizan una función de error se usan métodos de optimización matemática. Los algoritmos de aprendizaje más usados tratan de minimizar la suma de los cuadrados de los errores:

$$\begin{aligned} E(\omega) &= \sum_{j,p} (y_{jp} - \hat{y}_{jp})^2 = \sum_p \|y_p - \hat{y}_p\|^2 \\ &= \sum_{j,p} (y_{jp} - f(\sum_i \omega_{ji} x_{ip}))^2 = \sum_p \|y_p - f(\omega^T x_p)\|^2 \end{aligned} \quad (5.5)$$

Al no ser esta función lineal, no hay método alguno para obtener una solución exacta. Uno de los algoritmos de optimización más simples y que fue el que originalmente usaban las primeras redes neuronales feedforward para este problema es el método del descenso de gradiente, también conocido como *regla delta*. Este algoritmo trata de modificar incrementalmente los pesos de forma iterativa, de tal manera que el error vaya siendo más pequeño, siendo los pesos iniciales tomados aleatoriamente. El incremento de los pesos se obtiene a partir de los vectores del opuesto del gradiente de la función de error respecto de los pesos, es decir, cuando la función de error decrece con mayor rapidez. En cada iteración cada peso será modificado mediante una variación proporcional al gradiente del error:

$$\begin{aligned} \Delta\omega_{ji} &= -\eta \frac{\partial E(\omega)}{\partial \omega_{ji}} = -\eta \sum_p (y_{jp} - \hat{y}_{jp}) \frac{\partial \hat{y}_{jp}}{\partial \omega_{ji}} \\ &= -\eta \sum_p (y_{jp} - \hat{y}_{jp}) f'(\sum_i \omega_{ji} x_{ip}) x_{ip} \end{aligned} \quad (5.6)$$

donde η es la *tasa de aprendizaje*. Ésta es una constante positiva cuya función es moderar la cantidad de variación de los pesos entre los distintos pasos.

5.3.5. FUNCIONES DE ACTIVACIÓN DERIVABLES

El método del decrecimiento del gradiente, como su nombre indica, busca el mínimo de la función del error en el espacio de los pesos mediante el cálculo del gradiente de dicha función. La combinación de estos que la minimiza es considerada como la solución del algoritmo de aprendizaje. Para ello se usa un gradiente y en consecuencia hay que exigirle a la función que sea continua y derivable; una función de activación derivable hace que la función del error sea también derivable.

Las funciones de activación más usadas son:

- *Funciones sigmoideas*: Se trata de funciones monótonas acotadas que dan una salida no lineal gradual. Dentro de este tipo las más populares son:

- *Logística*, cuyo rango abarca de 0 a 1

$$f_c(x) = \frac{1}{1 + e^{-cx}} \quad (5.7)$$

- *Tangente hiperbólica*, su rango va de -1 a 1.




Figura 5.6: Función de activación logística (izquierda) y tangente hiperbólica (derecha).

- *Funciones núcleo*: se localizan alrededor de un punto. Un ejemplo de ella es la distribución Gaussiana.




Figura 5.7: Funciones de activación gaussianas.

- *Funciones lineales*: dan una salida lineal con un rango infinito.

$$f(x) = x \quad (5.8)$$

Las derivadas de algunas funciones de activación pueden ser definidas en términos de sus primitivas. Por ejemplo:

$$f(s) = \frac{1}{1 + e^{-cs}} = \frac{e^{-s}}{(1 + e^{-s})^2} \implies f'(s) = c f(s)(1 - f(s))$$

Otra función que puede ser definida en términos de sí misma:

$$f(s) = \tanh(cs) \implies f'(s) = c f(s)(1 - f(s)^2)$$

Si la función de activación es lineal ($f(s) = s$), las salidas serían una combinación lineal de las entradas y la variación de los pesos en cada paso sería:

$$\Delta\omega_{ji} = -\eta \frac{\partial E}{\partial \omega_{ji}} = \eta \sum_p (y_{jp} - \hat{y}_{jp}) x_{ip} \quad (5.9)$$

dando la solución global del problema lineal. Por lo tanto no sería necesario realizar una metodología iterativa sino una técnica de optimización lineal. El modelo resultante es análogo a un modelo de regresión lineal, siendo los pesos de la red sus parámetros.

5.3.6. REDES MULTICAPA

Los nodos de la capa de entrada alimentan la red hacia la siguiente capa oculta cuyas salidas continuarán este proceso hasta la salida. Generalmente se indica la topología de la red empleando el número de neuronas en cada capa.




Figura 5.8: Red multicapa de topología 4:4:2.

En este caso para cada una de las salidas, la red de dos capas (una oculta y otra de salida, ya que la de entrada nunca se cuenta) calcula las salida y_j de la forma:

$$y_j = f\left(\sum_k \beta_{jk} f\left(\sum_i \alpha_{ki} x_i\right)\right) \quad (5.10)$$

Las redes de una capa pueden considerarse como modelos de regresión lineal y logística bastante sencillo y poco útiles. En cambio, el añadir capas ocultas da lugar a modelos que pueden considerarse no paramétricos de regresión no lineal. Sin embargo, el diseño de este tipo de modelos resulta a veces problemático dado que no hay ninguna regla orientativa sobre el número de capas óptimo y el número de capas que ha de haber en cada una en un problema dado.

Cuando el diseño ya ha sido elegido, se procederá a realizar el aprendizaje, usando un método de optimización. El más popular es el conocido como *retro-propagación* o *backpropagation* y está basado en el método del descenso de gradiente explicado con anterioridad.

5.3.7. MÉTODO BACKPROPAGATION

Dados un conjunto de entradas $(x_{1p}, x_{2p}, \dots, x_{mp})$ y salidas $(y_{1p}, y_{2p}, \dots, y_{mp})$ siendo $p = 1, \dots, a$ usados como patrones de entrenamiento se tratará de minimizar el error

cuadrático total:

$$\begin{aligned} E(\alpha, \omega) &= \sum_{j,p} (y_{jp} - f(\sum_k \omega_{jk} h_{kp}))^2 \\ &= \sum_{j,p} (y_{jp} - f(\sum_k \omega_{jk} f(\sum_i \alpha_{ki} x_{ip})))^2 \\ &= \sum_p \|y_p - f(\omega^T f(\alpha^T x_p))\|^2 \end{aligned} \quad (5.11)$$

donde ω contiene las columnas de los vectores de pesos de la neurona j -ésima de la capa de salida, mientras que α los de la k -ésima neurona de la capa oculta.

En el *backpropagation* los pesos son modificados incrementalmente de manera proporcional al gradiente de la función de error:

$$\Delta\omega_{jk} = -\eta \frac{\partial E}{\partial \omega_{jk}}; \quad \Delta\alpha_{ki} = -\eta \frac{\partial E}{\partial \alpha_{ki}} \quad (5.12)$$

donde el término η es la tasa de aprendizaje y podría ser diferente para ambos conjuntos de pesos.

Dado que ahora la expresión para el error depende tanto de los pesos de neuronas ocultas como de los de las de salida la modificación de los valores de los pesos no resultará tan sencilla como cuando hay una capa. Los pasos del algoritmo se pueden enumerar de la siguiente manera.

1. Se inician los pesos con valores aleatorios.
2. Se eligirá un patrón de entrenamiento y será propagado hacia adelante obteniendo los valores \hat{h}_p e \hat{y}_p para las neuronas de capas ocultas y de salida respectivamente.
3. Se calculará el error relativo a las unidades de salida.:

$$\delta_{jp} = (y_{jp} - \hat{y}_{jp}) f'(\omega_j^T \hat{h}_p)$$

4. Se calculará el error relativo a las capas ocultas:

$$\psi_{jp} = \sum_k \delta_{jp} \omega_{jk} f'(\alpha_k^T x_p)$$

5. Se obtendrán los incrementos de los pesos:

$$\begin{aligned} \Delta\omega_{jk} &= \eta \delta_{jp} \hat{h}_{kp} \\ \Delta\alpha_{ki} &= -\eta \sum_j x_{ip} \delta_{jp} \psi_{jp} \end{aligned}$$

6. Este proceso se repetirá para cada patrón de entrenamiento.

Este método ha resultado no ser muy eficiente por lo que multitud de mejoras han sido propuestas [14]. También se ha optado por el uso de métodos alternativos, cambiando el descenso de gradiente por otras técnicas. Uno que es ampliamente usado en todos los softwares para la creación de redes neuronales es el *Levenberg-Marquardt*. La red fue implementada usando el *Toolbox* de Matlab que usa este algoritmo por defecto. Fue desarrollado a partir del método de *Gauss-Newton* y por ello se explicará este antes.

5.3.8. MÉTODO GAUSS-NEWTON

El método Gauss-Newton es una modificación del método de Newton. Consiste en encontrar el mínimo de una función mediante la búsqueda de los ceros de su derivada. Realizando una linearización de segundo orden y teniendo en cuenta un caso multidimensional:

$$E(\omega + \Delta\omega) \approx E(\omega) + J_{E(\omega)}^T \Delta\omega + \frac{1}{2} \Delta\omega^T H_{E(\omega)} \Delta\omega \quad (5.13)$$

donde $J_{E(\omega)}^T$ y $H_{E(\omega)}$ denotan el Jacobiano y la matriz Hessiana respectivamente.

Derivando para encontrar el mínimo se obtiene que la dirección en la que se producirán los incrementos de los pesos es:

$$\Delta\omega = -\eta H_{E(\omega)}^{-1} J_{E(\omega)}^T \quad (5.14)$$

El cálculo de la inversa de la matriz Hessiana es muy costoso. Realizando una linearización y despreciando los términos de segundo orden se puede aproximar la matriz Hessiana como el producto escalar del Jacobiano. Finalmente se obtiene:

$$\Delta\omega = -\eta [J_{E(\omega)}^T J_{E(\omega)}]^{-1} J_{E(\omega)} \quad (5.15)$$

5.3.9. MÉTODO LEVENBERG-MARQUADT

El algoritmo Levenberg-Marquardt surge de realizar una modificación del método de Gauss-Newton. Consiste en añadir un término de regularización en el método de Gauss-Newton llamado parámetro de Marquardt.

$$\Delta\omega = -\eta [J_{E(\omega)}^T J_{E(\omega)} + \mu I]^{-1} J_{E(\omega)} \quad (5.16)$$

Este método resulta ser una interpolación de los dos anteriores en función del valor que tome el parámetro de Marquardt. Así, aúna las mejores propiedades de los dos. Cuando la solución en la iteración presente se aleja de la solución buscada el algoritmo se comporta como el descenso de gradiente, es decir, lento pero garantiza la convergencia a una solución. El parámetro de Marquardt toma valores elevados en este caso. En cambio, cuando está próxima a la solución buscada se convierte en el método de Gauss-Newton, alcanzando una solución en un número mucho menor de iteraciones, tomando un valor nulo el término de regularización.

CAPÍTULO 6

DESARROLLO DEL PROYECTO

En este capítulo se relata el proceso que ha sido seguido, desde la obtención de datos hasta las pruebas realizadas en la parametrización de la red neuronal, explicándose esto en sendas secciones. Además, un breve análisis de los datos obtenidos ha sido llevado a cabo y usado en el diseño de la red. Finalmente, se ha realizado un resumen y estudio de los resultados.

6.1. OBTENCIÓN DE DATOS

Como ha sido explicado en la introducción, lo primero a efectuar en el desarrollo del proyecto fue correr la simulación del WRF.

La parametrización del WRF viene dada en los ficheros `namelist.input` y `namelist.wps`, explicados en el capítulo 4. Para controlar estos ficheros y hacer posible la simulación de manera continua mediante el copiado de archivos, han sido usados archivos creados en Bash scripting de Linux y en NCL para extraer los valores de los archivos de salida del WRF.

Como ya ha sido dicho, los datos obtenidos para realizar el experimento son de Ciudad Universitaria en Madrid, con coordenadas 40.4528° Norte y 3.7242° Oeste. El WRF fue configurado con estas coordenadas y ejecutado.

La duración de la simulación ha sido de dos días.

Tal y como está configurado el WRF las salidas vienen dadas en una estructura de carpetas creada mediante los ficheros de Bash scripting. Dicha estructura de carpetas contiene una por mes y día de éste. Dentro de cada carpeta se encuentran los ficheros de texto con los resultados. Se escribe un fichero por cada variable y hora del día. Los datos meteorológicos obtenidos son cantidad de vapor de agua en las nubes (Qcloud), presión, temperatura, humedad relativa y las componentes del viento dadas según el sistema de coordenadas del modelo, además de sendos ficheros con las correspondiente coordenadas de latitud y longitud (*lat.txt* y *lon.txt*) (ver figura 6.3).



Figura 6.1: Esquema de carpetas con el que se ha trabajado (meses).

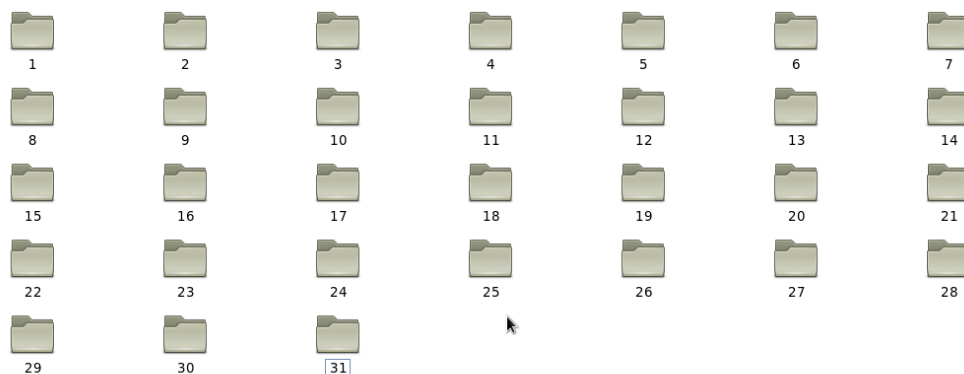


Figura 6.2: Esquema de carpetas con el que se ha trabajado (días del mes).

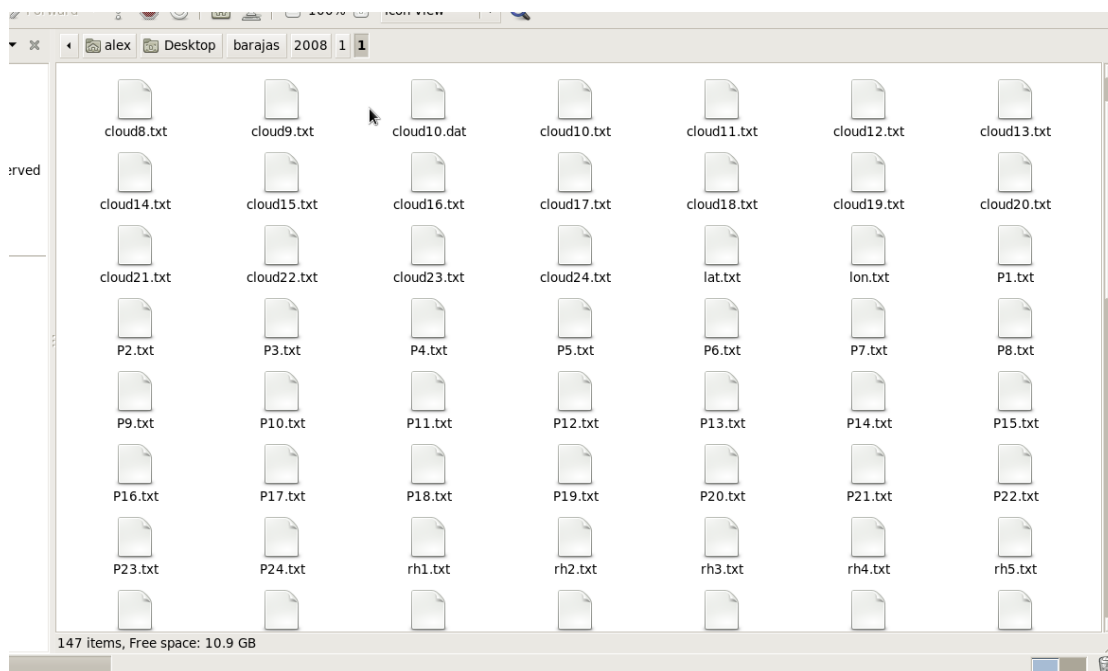


Figura 6.3: Archivos de texto con los valores obtenidos del WRF.

Cada uno contendrá 196 valores escritos en columna exceptuando los de Qcloud que al tener 27 niveles contendrá 5292 valores.

Para extraer los datos de los archivos se ha utilizado una función programada en

Matlab. Esta obtiene el punto más próximo a la ubicación de interés mediante la carga de los ficheros *lat.txt* y *lon.txt*. El criterio usado para determinar la ubicación más cercana es seleccionar la que reduzca la distancia euclidiana con respecto a las coordenadas dadas (ver figuras 6.4 y 6.6).




Figura 6.4: Mallado del WRF y punto seleccionado.

Una vez elegido el punto, con el fin de obtener un valor más preciso al real, se calcula la media de los puntos más cercanos, ya que es sabido que el orden del mallado del WRF es siempre de la siguiente forma:




Figura 6.5: Mallado del WRF.




Figura 6.6: Mallado del WRF y puntos más cercanos.

El procedimiento para el cálculo del índice de nubosidad sigue lo explicado en el apartado 4.6.4.

El siguiente paso en la función es correr la rutina de posición solar para pasar a calcular la DNI mediante el MRM.

Como se ha explicado en la sección 3.16 los datos para el parámetro β son obtenidos a partir de los datos suministrados por *Globaerosol*. En concreto, los valores más próximos para la ubicación de Ciudad Universitaria se muestran en el anexo C.

A continuación se ha obtenido un valor mensual medio del parámetro de turbidez para los cinco años:

Tabla 6.1: Parámetros de turbidez medios mensuales.

Mes	Beta
Enero	0.040
Febrero	0.031
Marzo	0.021
Abril	0.021
Mayo	0.023
Junio	0.038
Julio	0.041
Agosto	0.038
Septiembre	0.037
Octubre	0.030
Noviembre	0.027
Diciembre	0.026

Estos valores han sido guardados en una fichero de texto para luego ser cargados por

la función programada y ser utilizados en el MRM.

Los datos obtenidos para la DNI quedan reflejados en las figuras 6.7 y 6.8.

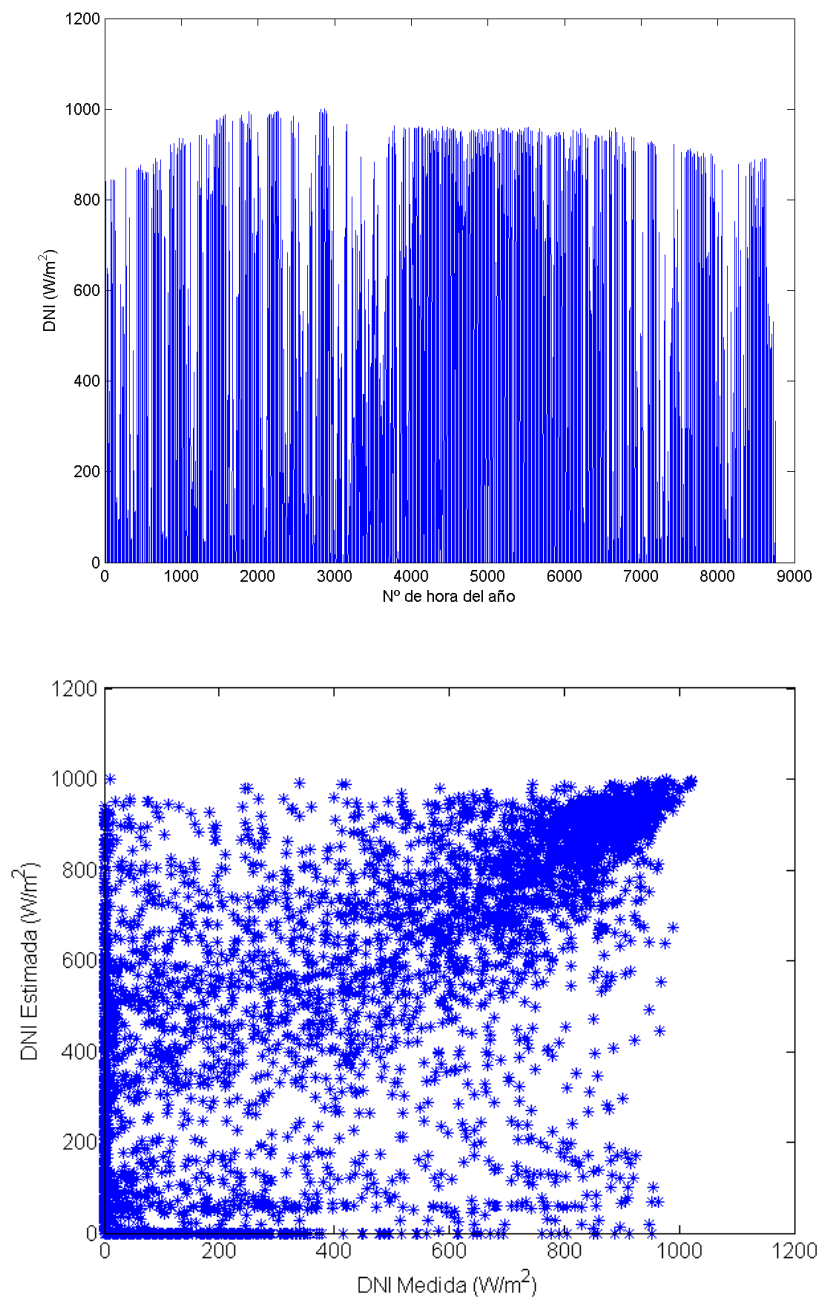


Figura 6.7: DNI obtenida a lo largo del año y diagrama de dispersión frente a datos medidos para el año 2008.




Figura 6.8: DNI obtenida a lo largo del año y diagrama de dispersión frente a datos medidos para el año 2009.

6.2. ANÁLISIS DE DATOS OBTENIDOS

Con el fin de tener alguna idea más clara de las dependencias y correlaciones de estas variables entre sí, se ha realizado un breve estudio previo a la modelización de la red. Para ello se ha calculado la matriz de coeficientes de correlación mediante Statgraphics. Las variables expuestas son: temperatura, presión, humedad relativa, Irradiancia Global Horizontal, Irradiancia Difusa Horizontal, Irradiancia Directa Normal medida, ángulo y velocidad del viento y variación de temperatura.

Tabla 6.2: Matriz de correlaciones.

-	T	P	HR	GHI	DHI	DNI	Áng.	Vel.	ΔT
T	1	-0,043	-0,811	0,491	0,480	0,488	0,225	-0,004	-0,080
P	-0,043	1	0,024	-0,019	-0,051	0,055	0,302	-0,251	0,0455
HR	-0,811	0,024	1	-0,647	-0,627	-0,671	-0,125	-0,003	-0,069
GHI	0,491	-0,019	-0,647	1	0,981	0,867	0,184	-0,059	0,481
DHI	0,480	-0,051	-0,627	0,981	1	0,831	0,203	-0,040	0,474
DNI	0,487	0,055	-0,671	0,867	0,831	1	0,108	-0,114	0,417
Ángulo v.	0,225	-0,303	-0,125	0,184	0,203	0,108	1	0,013	0,0193
Veloc. v.	-0,004	-0,251	-0,003	-0,059	-0,040	-0,114	0,013	1	-0,181
ΔT	-0,080	0,0455	-0,069	0,481	0,474	0,417	0,0193	-0,181	1

Esta matriz nos da información acerca de las posible correlaciones lineales entre las variables. Un valor próximo a 1 indicará una correlación lineal fuerte positiva y -1 negativa, es decir, inversamente proporcional. Que las variables no tengan una correlación lineal no quiere decir que no exista ninguna relación entre ellas.

Observando los datos se aprecia un valor significativo para el coeficiente de correlación entre la humedad relativa y la temperatura. Esto tiene sentido ya que al aumentar la temperatura disminuye la humedad relativa. La información adicional que nos aporta este análisis es que es de forma lineal. Otros coeficientes de correlación significativos son los que relacionan las variables de las componentes de la irradiancia lo cual es también lógico. El resto de variables meteorológicas no presentan ninguna correlación lineal excesivamente significativa con la DNI a priori, lo cual justifica el uso de un modelo no lineal como es una red neuronal.

En las figuras 6.9, 6.10, 6.11, 6.12, 6.13, 6.14, 6.15, 6.16 y 6.17 se muestran algunos gráficos de dispersión. En ellas se corrobora lo dicho. De los gráficos T-DNI (figura 6.10) y HR-DNI (figura 6.12) sí que se aprecia que pueda haber alguna relación sin que sea lineal. Por otra parte, del diagrama P-DNI (figura 6.11) a primera vista parece que es constante aunque sí que se vislumbran valores bajos de la presión para valores casi nulos o nulos de DNI lo cual puede explicarse mediante la relación que tiene la presión sobre la nubosidad. Respecto al viento (véase figura 6.14), no es fácil encontrar alguna relación con la velocidad, aunque tal vez sí que exista dado que se puede observar que las mayores velocidades del viento coinciden con valores de DNI medidos casi nulos o nulos. En cuanto a la dirección (véase figura 6.13) no aparece ninguna que sea especialmente significativa. Finalmente, la variación de temperatura tampoco aparenta relación alguna con la DNI (véase figura 6.17), a excepción de que existe una menor variabilidad de las diferencias de temperatura con valores altos de irradiancia, no existiendo apenas caídas

importantes en los valores de la temperatura.




Figura 6.9: Gráfico de dispersión temperatura (°C) vs humedad relativa (%).




Figura 6.10: Gráfico de dispersión temperatura (°C) vs DNI (W/m^2).




Figura 6.11: Gráfico de presión (bar) vs DNI (W/m^2).




Figura 6.12: Gráfico de dispersión humedad relativa (%) vs DNI (W/m^2).




Figura 6.13: Gráfico de dispersión ángulo del viento ($^\circ$) vs DNI (W/m^2).




Figura 6.14: Gráfico de velocidad del viento (m/s) vs DNI (W/m^2).




Figura 6.15: Gráfico de dispersión GHI (W/m^2) vs DNI (W/m^2).




Figura 6.16: Gráfico de dispersión DHI (W/m^2) vs DNI (W/m^2).




Figura 6.17: Gráfico de dispersión variación de temperatura ($^{\circ}\text{C}$) vs DNI (W/m^2).

6.3. PARAMETRIZACIÓN DE LA RED NEURONAL

Se ha realizado un breve análisis de los datos obtenidos. Se ha tratado que esta información haya sido usada a la hora de elegir los inputs de la red neuronal. Sin embargo, las conclusiones que se hayan podido adquirir aquí se habrán de verificar con los resultados experimentales.

Inicialmente se han efectuado varias pruebas para desenvolverse con la red neuronal. Estas no se recogen en este documento, dada su poca relevancia.

Para la elaboración de la red se ha usado el *Toolbox* de Matlab para redes neuronales. Antes de comenzar a explicar los experimentos llevados a cabo se realizará una breve introducción a dicha herramienta.

Matlab ofrece la posibilidad de realizar los modelos de red mediante un interfaz gráfico específico para cada tarea que se quiera llevar a cabo con el tipo de red neuronal indicada. Tiene además otro interfaz que permite seleccionar cualquier tipo de red. Por otra parte, también posibilita al usuario implementar la red mediante la programación de scripts y funciones, como ha sido el caso. En ambas opciones, al hacer el entrenamiento otro interfaz gráfico asiste al modelizador. Aquí se encuentra la información del estado del entrenamiento. Su apariencia varía en función del tipo de entrenamiento elegido y tipo de red. En el caso en cuestión se entrenó una red feedforward con el algoritmo Levenberg-Marquardt.

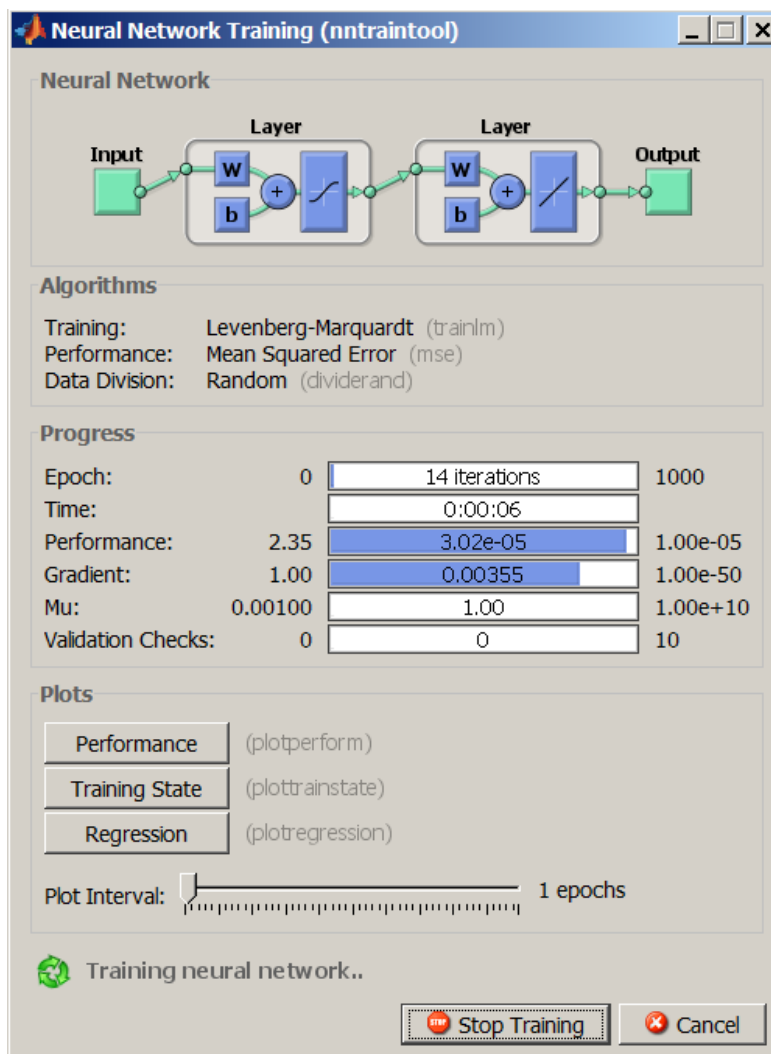


Figura 6.18: Interfaz de entrenamiento de redes neuronales de Matlab.

En la figura 6.18 de arriba a abajo vienen indicados:

- *Neural Network*: aquí se indica el número de capas y funciones de activación vienen indicados con un esquema en la parte superior. Por defecto Matlab asignará una función de activación lineal por cada salida que tenga la red, por lo que solo hará falta indicar el número de capas ocultas.
- *Algorithms*: se indica de arriba a abajo el algoritmo de entrenamiento (Levenberg-Marquardt), el de medida del error (error cuadrático medio) y para la división de datos (aleatorio).
- *Progress*:
 - Se indican las épocas o iteraciones realizadas siendo el final de la barra de progreso el número que ha sido indicado por el usuario y el tiempo empleado.
 - El performance o rendimiento, el cual es una medida de los errores que se cometen con la red.

- El gradiente que no es más que el gradiente que se está obteniendo en la función de error. Gradientes pequeños indicarán ‘superficies planas’ y por lo tanto la convergencia de la red y la obtención de un mínimo.
 - El parámetro de Marquardt o Mu que indica si la solución está convergiendo o no. Como ha sido explicado valores altos el algoritmo será descenso de gradiente y valores casi nulos el método de Gauss-Newton.
 - El número de pruebas de validación cruzada en el que el error de validación no disminuye junto con el de entrenamiento por lo que la red estará perdiendo su capacidad de generalizar los problemas.
- *Plots*: de arriba a abajo te dan un gráfico de medida del performance, del estado del entrenamiento y gráficos de regresión (ver figuras 6.19, 6.20 y 6.21).




Figura 6.19: Gráfico del performance del entrenamiento en el interfaz de Matlab.




Figura 6.20: Gráfico del estado de algunos parámetros de entrenamiento en el interfaz de Matlab.

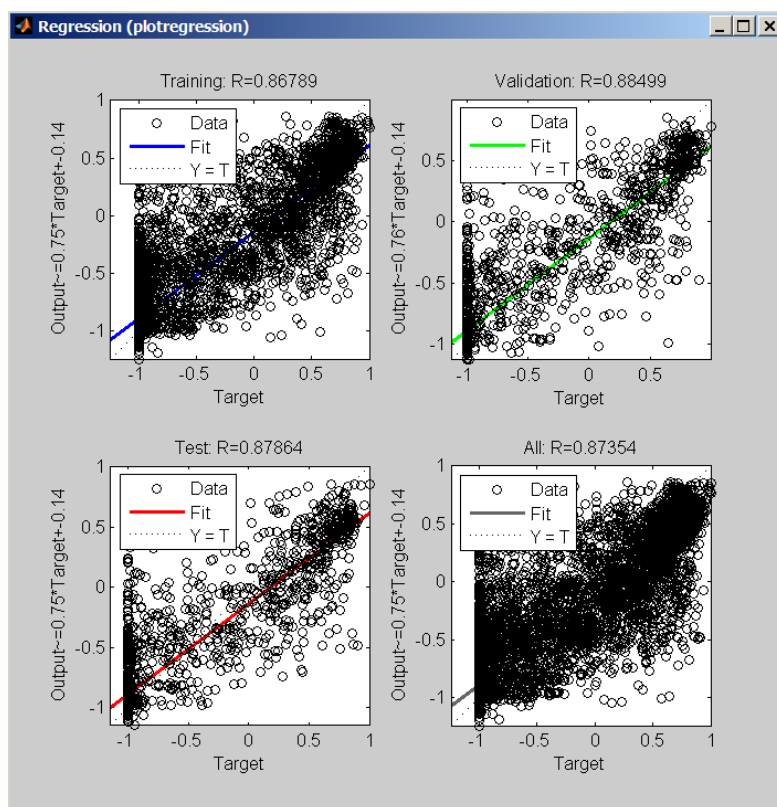


Figura 6.21: Gráficos de regresión del entrenamiento del interfaz de Matlab.

El objetivo de este proyecto no es la parametrización de una red neuronal para la predicción de la DNI, sino para la corrección de la DNI de un modelo dado (MRM). Por ello, la variable fundamental en la entrada de la red es precisamente la DNI del MRM. En las pruebas esta permanecerá fija y se tratará de buscar la mejor combinación del resto. Por ello, ha surgido la idea de inicializar los pesos de la red a dicha variable. ¿Cómo realizar esto? Matlab permite manipular los pesos de una red. Dado que esta tarea es de cierta complejidad se ha optado por implementar en el script un entrenamiento previo de la red neuronal de tal forma que tomara como patrones de salida los valores de DNI del MRM. Los pesos adoptarán valores adecuados de tal manera que al realizar un segundo entrenamiento este comenzaría desde la DNI estimada para ir ajustándose a la DNI real. Esta red previa se denotará de ahora en adelante como *red 1*.

Matlab usa por defecto la validación cruzada. Para ello por defecto selecciona un set de datos de los patrones de entrenamiento y lo utiliza para realizar una prueba de validación como fue explicado en el apartado 5.3.3. También escoge un set de datos de *test*, es decir, para evaluar la capacidad de predicción del modelo. Las proporciones estándar que usa son 15 % para cada uno de estos set de datos siendo el 70 % para el entrenamiento. La forma en que se escogen los datos de los sets puede ser modificada. Así, Matlab elige los sets por defecto usando el criterio *dividerand* que consiste en elegirlos aleatoriamente. Con el fin de que reducir la aleatoriedad de los experimentos, las proporciones de datos para validación y de *test* han sido disminuidas a cero.

Lo primero que se ha realizado es la selección de los parámetros de entrenamiento para la *red 1*. Se ha buscado un performance muy bueno ya que este es fácil de conseguir. Por ello se ha impuesto una condición de parada para el gradiente de 10^{-50} un valor muy pequeño y por tanto difícil de alcanzar; el número de iteraciones máximas ha sido 1000. Tras varias pruebas se ha comprobado que un performance de 10^{-5} ya es lo suficientemente bueno para ajustar los pesos a la DNI del MRM y éste es el criterio de parada que antes es alcanzado por la *red 1*.

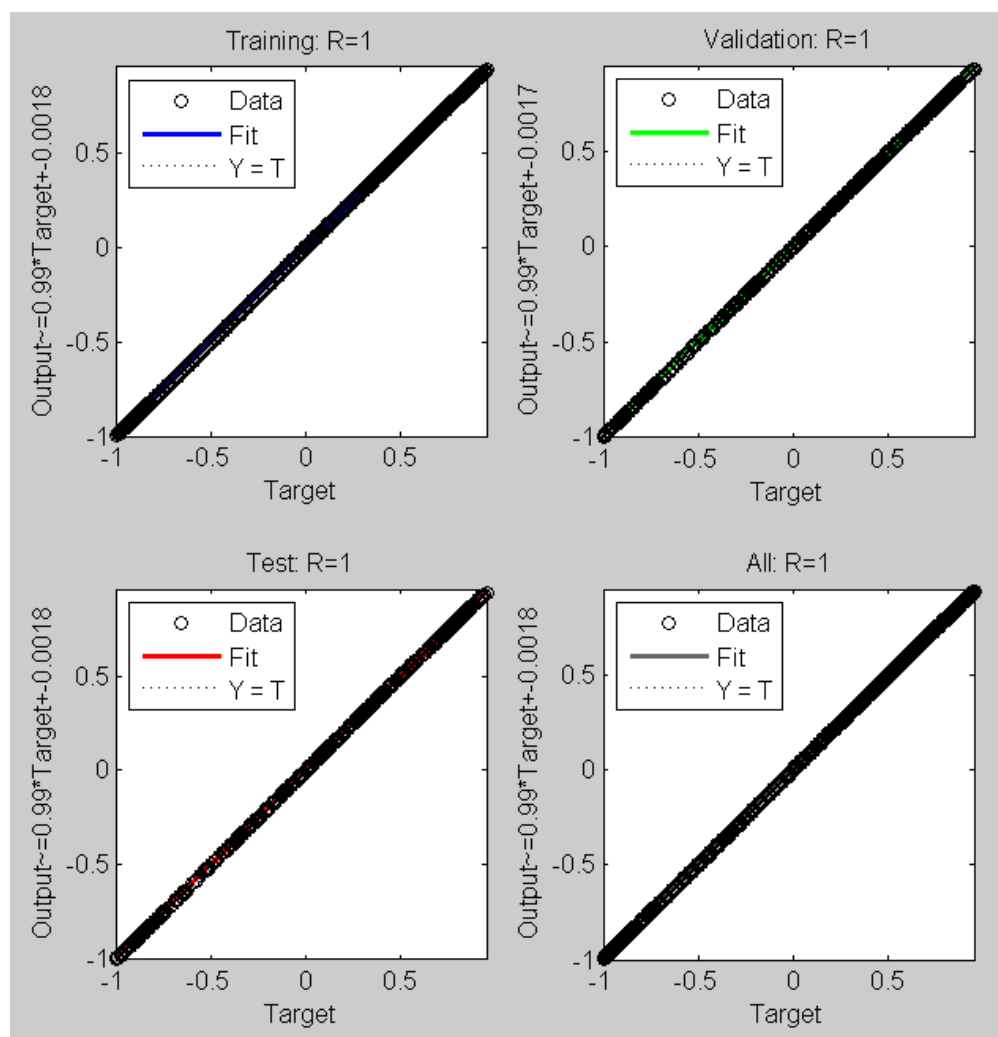


Figura 6.22: Gráficos de regresión del entrenamiento de la red 1.

Los valores de -1 y 1 de la figura 6.22 se debe a que los datos a introducir en la red han de estar normalizados, es decir, comprendidos entre los mismos valores máximo y mínimo. Es muy recomendable llevar a cabo la normalización de los datos para conseguir un entrenamiento más eficiente.

6.3.1. EXPERIMENTOS

A continuación se detallarán los experimentos llevados a cabo y los resultados obtenidos. En ellos se ha usado el 100 % de la muestra para realizar el entrenamiento. Se han entrenado las redes con el año 2008 y se ha tratado de predecir el 2009. El criterio para cuantificar el error obtenido al realizar la predicción del siguiente año ha sido la raíz cuadrada del error cuadrático medio (RMSE). También se ha calculado el sesgo o en inglés *Mean Bias Error* (MBE), que da una idea de cuánto sobreestima o subestima de media el valor estimado al valor real.

Para referirse a los experimentos con mayor claridad se han denotado con un número seguido de una letra, en función de su similitud.

Con el fin de facilitar el seguimiento de los experimentos llevados a cabo, se adjunta la tabla 6.3.

Tabla 6.3: Experimentos llevados a cabo.

Experimento	Variables	1ª capa oculta & 2ª
1A	DNI, P, T, Día del año, Hora	5 & 0
1B	DNI, P, T, Día del año, Hora	30 & 0
1C	DNI, P, T, Día del año, Hora	15 & 0
1D	DNI, P, T, Día del año, Hora	12 & 3
1E	DNI, P, T, Día del año, Hora	5 & 2
1F	DNI, P, T, Día del año, Hora	5 & 0
2A	DNI, P, T, Día del año, Hora, HR	5 & 0
2B	DNI, P, T, Día del año, Hora, HR	15 & 0
3A	DNI, P, T, Día del año, Hora, HR, Vel. viento	5 & 0
3B	DNI, P, T, Día del año, Hora, HR, Vel. viento	15 & 0
4A	DNI, P, T, Día del año, Hora, Vel. viento	5 & 0
4B	DNI, P, T, Día del año, Hora, Vel. viento	15 & 0
5A	DNI, P, T, Día del año, Hora, Vel. viento, Dir. viento	5 & 0
5B	DNI, P, T, Día del año, Hora, Vel. viento, Dir. viento	15 & 0
6A	DNI, P, T, HR, Vel. viento, Dir. viento, Elevación	5 & 0
6B	DNI, P, T, HR, Vel. viento, Dir. viento, Elevación	15 & 0
7A	DNI, P, T, HR, Vel. viento, Dir. viento, Elevación, GHI	5 & 0
7B	DNI, P, T, HR, Vel. viento, Dir. viento, Elevación, GHI	15 & 0
8A	DNI, P, T, HR, Vel. viento, Dir. viento, Elevación, DHI	5 & 0
8B	DNI, P, T, HR, Vel. viento, Dir. viento, Elevación, DHI	15 & 0
9A	DNI, P, ΔT , HR, Vel. viento, Dir. viento, Elevación, DHI	5 & 0
9B	DNI, P, ΔT , HR, Vel. viento, Dir. viento, Elevación, DHI	15 & 0
10A	DNI, P, ΔT , Día del año, Hora	5 & 0
10B	DNI, P, ΔT , Día del año, Hora	15 & 0
11A	DNI, P, ΔT , HR, Vel. viento, Elevación, DHI	5 & 0
11B	DNI, P, ΔT , HR, Vel. viento, Elevación, DHI	15 & 0
12A	DNI, P, ΔT , HR, Vel. viento, Dir. viento, Elevación, DHI	12 & 6
12B	DNI, P, ΔT , HR, Vel. viento, Dir. viento, Elevación, DHI	20 & 0
12C	DNI, P, ΔT , HR, Vel. viento, Dir. viento, Elevación, DHI	10 & 5
12D	DNI, P, ΔT , HR, Vel. viento, Dir. viento, Elevación, DHI	15 & 0

En el primer caso se ha utilizado una red neuronal con entradas la DNI, presión, temperatura, un vector con el día del año correspondiente y otro con la hora. Este modelo base ha sido elegido así debido a que se ha considerado que estas variables son las que mayor información poseen y más fiable, observados los datos en el apartado 6.2. Se ha estimado que los vectores de hora y día del año son necesarios.

Esta misma red se probó con diferentes topologías. Como ha sido explicado, la validación cruzada ha sido desactivada y el procedimiento ha sido probar cada topología con diferente número de iteraciones. En los experimentos 1A, 1B y 1C, se han entrenado tres redes con dichos inputs y topologías de 5, 15 y 30 perceptrones respectivamente.

Tabla 6.4: Resultados experimento 1A.

Prueba	RMSE	MBE	Iteraciones
1	162.0205	-14.9518	20
2	159.8797	-15.0123	20
3	167.2053	-15.5117	20
4	160.8651	-14.3716	20
5	169.1081	-16.3387	20
6	160.5295	-12.8579	50
7	159.7715	-13.1789	50
8	158.75431	-12.1801	50
9	158.0404	-11.8645	50
10	160.45461	-14.9144	50
11	157.8008	-10.9597	100
12	160.0313	-14.2675	100
13	161.9032	-12.7452	100
14	159.6482	-12.7452	100
15	162.4874	-13.4899	100
16	160.7696	-10.5179	200
17	159.6637	-13.6530	200
18	160.2060	-10.0800	200
19	159.6638	-12.3632	200
20	160.7992	-10.4345	200

Tabla 6.5: Resultados experimento 1B.

Prueba	RMSE	MBE	Iteraciones
1	165.2545	-15.3266	20
2	162.8500	-14.3988	20
3	162.2107	-11.9306	20
4	165.4557	-11.3169	20
5	166.3133	-12.6886	20
6	169.3058	-16.0304	50
7	169.3246	-11.9708	50
8	164.4960	-15.7929	50
9	165.9702	-12.6212	50
10	170.2103	-11.9175	50
11	165.6956	-10.3588	100
12	171.0032	-14.4336	100
13	167.3522	-13.0508	100
14	169.3546	-15.9585	100
15	169.5830	-15.5403	100
16	166.7345	-12.1729	200
17	172.4087	-14.8889	200
18	171.5560	-14.5373	200
19	167.2971	-18.3359	200
20	170.3983	-14.8954	200

Tabla 6.6: Resultados experimento 1C.

Prueba	RMSE	MBE	Iteraciones
1	159.7888	-14.5015	20
2	160.9315	-12.5654	20
3	160.0468	-11.4201	20
4	159.6783	-11.6568	20
5	158.9244	-7.8848	20
6	164.4715	-12.8127	50
7	162.0864	-13.4351	50
8	159.1838	-9.1547	50
9	162.2435	-14.2773	50
10	162.0315	-9.8796	50
11	162.9529	-11.1841	100
12	160.7651	-10.68861	100
13	161.8795	-9.7384	100
14	165.5419	-16.5998	100
15	161.97740	-15.5567	100
16	159.7795	-9.60971	200
17	163.9590	-10.5954	200
18	162.5183	-13.9393	200
19	161.0477	-11.1694	200
20	163.6863	-11.3685	200

Se ha comprobado que 30 perceptrones en una única capa oculta son demasiados porque la red no mejora la predicción sino todo lo contrario. Por esta razón no se ha vuelto a usar esta topología en el resto de experimentos. Una segunda capa oculta ha sido probada: se han efectuado dos pruebas diferentes, una con una topología 12 y 3 perceptrones (1D) en las capas ocultas y otra con 5 y 2 (1E) en ese orden.

Tabla 6.7: Resultados experimento 1D.

Prueba	RMSE	MBE	Iteraciones
1	160.9873	-13.2323	20
2	160.1673	-13.4684	20
3	161.4061	-12.2943	20
4	161.0965	-14.3180	20
5	161.8936	-12.5116	20
6	164.2792	-18.8358	50
7	167.3246	-11.9708	50
8	164.0960	-15.7929	50
9	170.0043	-12.6212	50
10	169.2103	-11.9175	50
11	171.9891	-25.2610	100
12	166.6992	-16.9171	100
13	168.5639	-15.2609	100
14	174.5435	-18.55195	100
15	169.5193	-15.2344	100
16	170.4858	-15.3045	200
17	170.4118	-17.1690	200
18	168.3705	-13.1993	200
19	165.6025	-15.3987	200
20	167.7872	-13.9454	200

Tabla 6.8: Resultados experimento 1E.

Prueba	RMSE	MBE	Iteraciones
1	159.3235	-12.5142	20
2	158.2978	-12.2759	20
3	161.39671	-19.0764	20
4	173.1347	-22.2280	20
5	164.5493	-12.5327	20
6	158.5549	-12.7187	50
7	166.1817	-18.8751	50
8	159.6675	-13.4181	50
9	160.2905	-11.6202	50
10	159.1347	-12.9635	50
11	159.7293	-13.6116	100
12	164.3593	-11.6568	100
13	159.7081	-14.6582	100
14	158.7461	-14.35355	100
15	159.4450	-13.4784	100
16	159.7595	-16.0789	200
17	158.5193	-12.0076	200
18	160.15615	-13.1693	200
19	160.7709	-12.2250	200
20	160.7173	-14.7494	200

No se han obtenido unos mejores resultados con dos capas ocultas por lo que a partir de aquí se han utilizado redes de una capa para la prueba de las variables de entrada. El siguiente experimento (1F) ha sido probar el efecto de cambiar la función de activación. Anteriormente ha sido usada una tangente sigmoideal, que es la que Matlab utiliza por defecto. La sigmoideal logarítmica ha sido usada en su lugar.

Tabla 6.9: Resultados experimento 1F.

Prueba	RMSE	MBE	Iteraciones
1	160.2812	-11.6654	20
2	159.8768	-13.4453	20
3	160.8521	-14.8018	20
4	163.5473	-17.9323	20
5	160.0404	-9.2907	20

La topología elegida en el 1F para efectuar la comparación ha sido de 15 perceptrones. Se han llevado a cabo sólo las pruebas con 20 iteraciones dado que con este número es cuando se ha comprobado que salían los mejores resultados (se está comparando respecto del experimento 1C). No se han obtenido resultados muy diferentes así que para futuros experimentos se ha continuado usando la tangente sigmoideal. Hay muchas y diferentes funciones de activación que tal vez pudieran variar los resultados de forma significativa. Al no ser este el objetivo del proyecto no se ha realizado un análisis más exhaustivo sobre ellas.

En los siguientes dos experimentos la humedad relativa ha sido añadida a la red. Se han efectuado las pruebas con la topología de una red de 5 perceptrones (2A) y 15 perceptrones (2B) en la capa oculta en ese respectivo orden.

Tabla 6.10: Resultados experimento 2A.

Prueba	RMSE	MBE	Iteraciones
1	152.7536	-8.4086	20
2	150.5327	-8.5856	20
3	151.0745	-6.8207	20
4	149.3969	-5.6058	20
5	148.4034	-6.6698	20
6	152.2206	-2.767	50
7	149.3968	-3.6741	50
8	146.2937	-2.7911	50
9	149.2933	-4.7018	50
10	146.8547	-6.7505	50
11	150.3144	-7.0006	100
12	148.3113	-3.8711	100
13	151.5568	-6.2665	100
14	148.0337	-4.6372	100
15	146.3782	-5.7696	100
16	146.8302	-5.2411	200
17	151.0869	-6.7895	200
18	151.6511	-7.5207	200
19	148.0048	-0.2176	200
20	147.5049	-5.6382	200

Tabla 6.11: Resultados experimento 2B.

Prueba	RMSE	MBE	Iteraciones
1	148.3130	-3.7290	20
2	147.5412	-6.8558	20
3	148.9542	-5.0089	20
4	148.5360	-2.5294	20
5	148.9836	-2.5140	20
6	152.6629	-3.6361	50
7	149.8341	-3.6588	50
8	151.1411	-4.2676	50
9	153.2789	-6.2400	50
10	149.9688	-3.5022	50
11	149.8920	-3.8328	100
12	150.9298	-2.7142	100
13	150.6654	-1.1757	100
14	153.9316	-3.7727	100
15	152.3700	-1.6541	100
16	154.2883	-2.4782	200
17	154.3104	-5.0728	200
18	151.2884	-6.2348	200
19	153.5908	-2.5784	200
20	150.5818	-3.5211	200

Los siguientes dos experimentos (3A y 3B) han sido realizados añadiendo la variable velocidad del viento respecto a los 2A y 2B (es decir, tiene como variables DNI, P, T, Día del año, Hora, HR y Velocidad del viento). En el 3A la red ha sido configurada con una topología de 5 neuronas en la capa oculta y en el 3B, 15.

Tabla 6.12: Resultados experimento 3A.

Prueba	RMSE	MBE	Iteraciones
1	152.2770	-5.4752	20
2	154.8952	-8.7191	20
3	153.6227	-8.1209	20
4	151.5061	-6.6017	20
5	150.7071	-8.7052	20
6	153.6227	-8.1209	50
7	150.6492	-4.7673	50
8	153.0186	-5.0334	50
9	148.1033	-5.5628	50
10	151.2006	-7.7247	50
11	151.8249	-8.0723	100
12	149.9087	-5.3956	100
13	148.2925	-3.2908	100
14	149.3941	-5.6821	100
15	147.5986	-6.3657	100
16	152.2856	-5.6475	200
17	149.3513	-7.3284	200
18	149.5329	-1.7546	200
19	149.2936	-2.1047	200
20	156.1289	-10.5492	200

Tabla 6.13: Resultados experimento 3B.

Prueba	RMSE	MBE	Iteraciones
1	150.7021	-2.4748	20
2	147.83592	-3.2899	20
3	149.8465	-4.2681	20
4	153.2268	-6.6017	20
5	149.1218	-4.0768	20
6	149.0448	-4.9686	50
7	152.9526	-2.1835	50
8	153.3485	-4.3095	50
9	150.37009	-5.6704	50
10	151.3853	-4.7847	50
11	153.6221	-4.5293	100
12	154.0906	-4.9861	100
13	152.2985	-5.2460	100
14	151.1636	-1.7869	100
15	152.4898	-5.5301	100

Se ha observado que en el 3B ya con 100 iteraciones los resultados no han sido mejores por lo que se ha prescindido de las pruebas con 200 iteraciones. Por otra parte, la variable velocidad del viento no ha mejorado significativamente los resultados. Con el fin de verificar esto se han llevado a cabo otros experimentos (con variables DNI, P, T, Día del año, Hora y Velocidad del viento). Se ha probado con una topología de 5 y 15 perceptrones (4A y 4B respectivamente) en una capa oculta y se han comparado con 1A y 1C (es decir, las mismas variables pero sin Velocidad del viento).

Tabla 6.14: Resultados experimento 4A.

Prueba	RMSE	MBE	Iteraciones
1	168.3917	-16.6638	20
2	161.1222	-10.2624	20
3	160.1401	-18.1823	20
4	170.3051	-14.1290	20
5	157.0988	-14.1482	20
6	156.5908	-11.8652	50
7	156.7207	-8.9296	50
8	158.3897	-11.4954	50
9	156.3717	-11.8113	50
10	157.0563	-14.1482	50
11	156.1289	-10.5492	100
12	157.8702	-12.8311	100
13	158.2872	-13.1837	100
14	158.0984	-12.4672	100
15	161.0563	-14.1482	100
16	166.5335	-13.5114	200
17	157.7166	-14.8722	200
18	169.3571	-21.2833	200
19	156.2288	-11.8006	200
20	154.7671	-7.9963	200

Tabla 6.15: Resultados experimento 4B.

Prueba	RMSE	MBE	Iteraciones
1	162.9787	-20.8281	20
2	161.8324	-15.6229	20
3	157.5543	-9.9502	20
4	159.3776	-9.7794	20
5	156.5805	-6.4623	20
6	161.9789	-14.0410	50
7	156.7068	-14.7286	50
8	155.8902	-10.4668	50
9	169.3765	-22.7761	50
10	156.2060	-9.0623	50
11	157.0293	-11.0322	100
12	161.0320	-11.3424	100
13	159.6074	-13.7982	100
14	159.6074	-13.7982	100
15	155.7999	-14.4671	100

Estos resultados corroboran lo dicho anteriormente. La variable velocidad del viento no aporta gran información aunque parece que algo sí, por lo que para los próximos experimentos se mantendrá. En los siguientes (5A y 5B) la dirección del viento ha sido añadida al resto de variables del ejercicio anterior (es decir, ahora con DNI, P, T, Día del año, Hora, Velocidad del viento y Dirección del viento).

Tabla 6.16: Resultados experimento 5A.

Prueba	RMSE	MBE	Iteraciones
1	155.5916	-12.0100	20
2	154.2141	-6.7683	20
3	153.5263	-7.5710	20
4	154.5321	-8.0065	20
5	155.6427	-9.4721	20
6	153.5916	-9.6311	50
7	156.6927	-7.3060	50
8	159.2689	-7.5187	50
9	153.4945	-6.5377	50
10	154.0520	-6.0238	50
11	156.9707	-9.7598	100
12	154.5717	-7.3895	100
13	154.4119	-5.5640	100
14	154.5088	-8.2767	100
15	157.7440	-9.1278	100

Con 100 iteraciones ya no se han obtenido mejores resultados por lo que no se han realizado las pruebas con 200 iteraciones.

Tabla 6.17: Resultados experimento 5B.

Prueba	RMSE	MBE	Iteraciones
1	157.7802	-13.8561	20
2	156.7076	-11.8777	20
3	160.1985	-12.0708	20
4	163.7799	-14.7456	20
5	156.8738	-8.3413	20
6	155.2347	-9.3155	50
7	156.6813	-10.3973	50
8	155.8033	-14.3081	50
9	165.4136	-17.7870	50
10	156.3205	-14.3841	50
11	159.9857	-11.5375	100
12	155.9557	-10.3153	100
13	156.5680	-11.1230	100
14	157.1197	-13.4200	100
15	154.9782	-9.7575	100
16	161.8880	-11.2801	200
17	156.0454	-12.1785	200
18	156.5680	-11.1230	200
19	159.6060	-8.6695	200
20	156.01342	-9.8310	200

En los siguientes experimentos (6A y 6B) se ha probado el efecto conjunto de todas las variables estudiadas hasta el momento. Por otra parte, ha surgido la idea de cambiar las variables de hora y día del año por una única variable con información análoga a las otras dos: el ángulo de elevación del sol, o sea, las variables usadas son DNI, P, T, HR, Velocidad del viento, Dirección del viento y Elevación. Este cambio ayudaría a simplificar la red.

Tabla 6.18: Resultados experimento 6A.

Prueba	RMSE	MBE	Iteraciones
1	146.1125	-3.3924	20
2	145.6556	-5.7270	20
3	145.7537	-6.1102	20
4	144.3269	-2.4309	20
5	145.2893	-12.5259	20
6	151.2171	-6.3260	50
7	147.2070	-4.4912	50
8	151.9979	-1.5576	50
9	147.8725	-2.9133	50
10	147.7635	-4.2468	50

En el 6A con 50 iteraciones ya se han empeorado los resultados por lo que no se ha probado con 100 ni con 200; en el 6B no se ha probado con 200 por la misma razón.

Tabla 6.19: Resultados experimento 6B.

Prueba	RMSE	MBE	Iteraciones
1	146.1125	-3.3924	20
2	147.7910	-4.9598	20
3	144.8546	-6.2108	20
4	146.9089	-4.8769	20
5	148.6926	-8.2759	20
6	146.2956	-5.4041	50
7	146.6829	-6.3525	50
8	149.1935	-6.8099	50
9	147.3524	-6.7284	50
10	145.8945	-6.8052	50
11	146.9824	-5.9335	100
12	151.4019	-11.4023	100
13	148.5195	-6.5356	100
14	146.5373	-5.5687	100
15	150.1011	-7.0100	100

En los siguientes experimentos (7A y 7B) se ha añadido la GHI respecto de las entradas del ejercicio anterior.

Tabla 6.20: Resultados experimento 7A.

Prueba	RMSE	MBE	Iteraciones
1	145.8309	-7.2037	20
2	146.3116	-6.22780	20
3	144.7424	-5.7725	20
4	147.1866	-4.3759	20
5	148.1173	-5.3112	20
6	146.7401	-2.1177	50
7	146.7746	-3.0514	50
8	146.7746	-3.0514	50
9	147.0739	-3.6622	50
10	148.8385	-4.5283	50

Tabla 6.21: Resultados experimento 7B.

Prueba	RMSE	MBE	Iteraciones
1	145.2215	-5.6029	20
2	148.1160	-3.3465	20
3	147.4110	-3.4465	20
4	147.7668	-7.2496	20
5	149.9888	-5.3999	20
6	146.8080	-4.6456	50
7	147.0515	-4.2517	50
8	146.8295	-4.1387	50
9	149.0598	-3.6835	50
10	150.4995	-4.6014	50
11	148.3799	-6.9130	100
12	149.3919	-4.9957	100
13	150.0245	-7.0345	100
14	147.6970	-8.1684	100
15	148.165	-5.1231	100

No se ha apreciado mejora alguna con la adición de la GHI. Se han repetido los experimentos con la DHI en su lugar en los 8A y 8B.

Tabla 6.22: Resultados experimento 8A.

Prueba	RMSE	MBE	Iteraciones
1	150.9833	-7.6479	20
2	146.7879	-7.2667	20
3	146.9848	-6.8921	20
4	149.1931	-14.4256	20
5	147.2202	-7.1948	20
6	145.5454	-5.1626	50
7	148.5258	-6.7568	50
8	145.9152	-7.2643	50
9	147.9302	-5.3851	50
10	147.2449	-6.7241	50
11	146.2761	-6.9938	100
12	145.5354	-6.7568	100
13	147.7118	-5.6448	100
14	145.3610	-4.7209	100
15	147.9908	-6.9703	100
16	147.3735	-8.6336	200
17	147.4438	-7.0584	200
18	146.5133	-5.9323	200
19	148.6458	-7.7848	200
20	147.7983	-6.9362	200

Tabla 6.23: Resultados experimento 8B.

Prueba	RMSE	MBE	Iteraciones
1	148.0413	-6.0745	20
2	149.1337	-5.9537	20
3	145.6778	-0.6571	20
4	146.1532	-3.6422	20
5	146.4227	-3.9038	20
6	149.5446	-2.7821	50
7	152.4577	-3.4744	50
8	147.1205	-6.1111	50
9	146.9264	-7.1881	50
10	147.6598	-3.73601	50
11	147.4154	-4.6314	100
12	151.2401	-4.4832	100
13	148.2689	-4.0462	100
14	147.3933	-5.6564	100
15	148.4378	-4.9703	100

Los experimentos 8A y 8B han sido realizados con 5 y 15 neuronas respectivamente. A continuación, se ha probado a cambiar la temperatura por la serie de temperatura diferenciada en los experimentos 9A y 9B, siendo las variables DNI, P, ΔT , HR, Velocidad del viento, Dirección del viento, Elevación y DHI.

Tabla 6.24: Resultados experimento 9A.

Prueba	RMSE	MBE	Iteraciones
1	145.3610	-5.3947	20
2	148.6118	-8.4267	20
3	147.3636	-11.3275	20
4	147.2604	-5.3117	20
5	144.1562	-5.8169	20
6	146.2406	-6.8244	50
7	146.7186	-5.8835	50
8	144.8162	-6.1281	50
9	146.8574	-6.2160	50
10	147.1820	-6.3123	50
11	146.4564	-6.8677	100
12	144.8468	-6.2821	100
13	146.8133	-7.5735	100
14	144.4153	-4.2469	100
15	145.1500	-5.9260	100

Tabla 6.25: Resultados experimento 9B.

Prueba	RMSE	MBE	Iteraciones
1	145.6225	-5.6711	20
2	143.0718	-4.5008	20
3	144.8956	-6.9989	20
4	142.0923	-4.5510	20
5	142.6634	-2.5491	20
6	144.7517	-4.6348	50
7	144.7517	-4.6348	50
8	146.8409	-3.8744	50
9	146.3646	-4.6881	50
10	147.9092	-4.2635	50

Se ha querido estudiar hasta que punto la mejora es debido a presentar la temperatura de forma diferenciada. Para ello se ha cambiado en los experimentos 1A y 1C la temperatura por la variación de temperatura y han sido comparados en los 10A y 10B, siendo las variables DNI, P, ΔT , Día del año y Hora.

Tabla 6.26: Resultados experimento 10A.

Prueba	RMSE	MBE	Iteraciones
1	165.6672	-18.6201	20
2	159.9747	-17.7786	20
3	161.8938	-16.3263	20
4	163.0914	-17.9119	20
5	165.0006	-15.7615	20
6	168.7861	-16.6215	50
7	165.8847	-16.1624	50
8	163.9423	-15.5791	50
9	160.6852	-15.1876	50
10	161.3742	-14.2654	50
11	172.5908	-23.1045	100
12	164.5316	-15.6886	100
13	159.8280	-17.7733	100
14	159.6570	-14.8869	100
15	168.9542	-19.3980	100

Tabla 6.27: Resultados experimento 10B.

Prueba	RMSE	MBE	Iteraciones
1	158.8050	-16.5199	20
2	158.3081	-15.3792	20
3	158.0623	-11.8483	20
4	155.4956	-11.0289	20
5	158.6895	-17.9163	20
6	157.2270	-14.0518	50
7	157.1009	-13.7123	50
8	157.5353	-14.8672	50
9	157.6797	-14.52032	50
10	157.9156	-15.0730	50
11	159.0033	-15.4834	100
12	158.7480	-18.1450	100
13	158.0498	-14.3147	100
14	157.3091	-15.0249	100
15	158.5535	-13.3388	100

La mejor configuración obtenida es la del experimento 9B. Antes de comenzar una búsqueda más exhaustiva de los parámetros de entrenamiento con esas entradas, se ha querido comprobar si realmente la variable dirección del viento aporta algo de información o simplemente complica más el modelo, o sea, se han repetido los experimentos 9A y 9B sin la variable dirección del viento en los 11A y 11B.

Tabla 6.28: Resultados experimento 11A.

Prueba	RMSE	MBE	Iteraciones
1	144.8424	-5.7149	20
2	150.1450	-11.2648	20
3	146.4534	-5.0512	20
4	145.9910	-6.4576	20
5	146.1575	-7.8399	20
6	147.2327	-6.1259	50
7	146.8769	-6.4497	50
8	144.2407	-6.0633	50
9	148.1753	-9.0958	50
10	149.6829	-8.7095	50

Con 50 iteraciones no se mejoran los resultados por lo que no se han realizado las pruebas pertinentes con 100 y 200 iteraciones.

Tabla 6.29: Resultados experimento 11B.

Prueba	RMSE	MBE	Iteraciones
1	146.6127	-6.2352	20
2	146.3059	-4.2180	20
3	145.7869	-7.5022	20
4	145.2684	-7.2006	20
5	147.2650	-4.6595	20
6	151.0961	-5.3023	50
7	149.9202	-9.1274	50
8	147.7115	-7.0784	50
9	149.7107	-6.8050	50
10	149.1554	-7.6602	50
11	153.8249	-8.7373	100
12	150.5873	-6.7044	100
13	149.6037	-9.6624	100
14	148.1621	-7.3293	100
15	149.1277	-7.7652	100

Con 100 iteraciones los resultados han empeorado por lo que se ha decidido no hacer la prueba de 200 iteraciones. Además, sí que mejoran añadiendo la dirección del viento por lo que se mantendrá en la parametrización.

Los mejores resultados han sido obtenidos en el experimento 9B por lo que a continuación se ha procedido a buscar la mejor configuración de la red con esas entradas. Se han probado diferentes topologías; además se han realizado las pruebas con un número bajo de iteraciones ya que los mejores resultados en el 9B han sido obtenido con un número análogo de iteraciones.

Se han probado con topologías de 12-6, 20 y 10-5 neuronas en los experimentos 12A, 12B y 12C respectivamente.

Tabla 6.30: Resultados experimento 12A.

Prueba	RMSE	MBE	Iteraciones
1	145.6155	-8.7639	10
2	144.1318	-1.1363	10
3	142.0437	-5.3595	10
4	142.5077	-5.6351	10
5	144.0074	-7.7749	10
6	143.6130	-4.1767	20
7	146.1619	-8.0217	20
8	145.7869	-7.5022	20
9	145.2684	-7.2006	20
10	147.2650	-4.6595	20
11	146.7529	-6.7046	30
12	149.3075	-5.1072	30
13	149.0413	-6.9798	30
14	144.8485	-2.8949	30
15	146.0400	-7.9389	30

Tabla 6.31: Resultados experimento 12B.

Prueba	RMSE	MBE	Iteraciones
1	143.3976	-4.2568	10
2	143.0657	-5.9450	10
3	143.4667	-3.7545	10
4	146.0339	-8.2257	10
5	142.5470	-4.3102	10
6	143.3976	-4.2568	20
7	145.6172	-5.5242	20
8	143.0781	-5.5153	20
9	142.0621	-4.1986	20
10	143.7325	-2.4204	20
11	141.9612	-4.6269	30
12	147.8776	-5.7146	30
13	143.3529	-5.3146	30
14	145.8016	-4.9332	30
15	142.7411	-4.1176	30
16	148.1627	-6.0202	40
17	145.9935	-4.7227	40
18	142.8540	-7.2706	40
19	146.5582	-5.32032	40
20	146.9000	-4.6568	40

Tabla 6.32: Resultados experimento 12C.

Prueba	RMSE	MBE	Iteraciones
1	144.2896	-3.3747	10
2	144.4007	-6.7053	10
3	146.6265	-10.9239	10
4	145.1357	-8.3428	10
5	145.0067	-11.0147	10
6	145.8350	-5.7902	20
7	145.8163	-6.8094	20
8	145.51201	-4.47573	20
9	145.8672	-4.1250	20
10	146.2999	-3.8874	20
11	147.0572	-5.2004	50
12	150.2427	-5.2122	50
13	148.0111	-2.6865	50
14	148.2753	-4.3224	50
15	147.7490	-4.2141	50

En ésta al ser muy parecidos las pruebas de 10 y 20 iteraciones se ha proseguido directamente con la de 50 esperando percibir alguna diferencia.

Finalmente, se repetirá el experimento 9B con 10 y 30 repeticiones en el 12D.

Tabla 6.33: Resultados experimento 12D.

Prueba	RMSE	MBE	Iteraciones
1	142.4946	-6.4749	10
2	143.0374	1.0917	10
3	144.0908	-9.4269	10
4	143.0957	-5.3872	10
5	142.3172	-4.5807	10
6	143.6126	-5.6608	30
7	144.5672	-5.9688	30
8	144.4396	-6.9266	30
9	144.3626	-7.6501	30
10	145.4643	-4.8020	30

6.4. RESUMEN Y ANÁLISIS DE LOS RESULTADOS

En esta sección se pretende realizar un resumen de todos los experimentos en la realización de la red y resultados obtenidos a la vez que analizar brevemente dichos datos. Se han llevado a cabo diferentes tipos de pruebas cambiando parámetros. Por cada tipo de prueba se han efectuado cinco diferentes dado que los resultados obtenidos por una red neuronal no son siempre los mismos. El criterio elegido para cuantificar el error cometido y poder comparar más fácilmente los resultados es el filtrado de valores extremos (máximo y mínimo) y obtención de la media de los tres valores centrales. Se ha considerado que podría ser un buen criterio dado que se ha visto que es frecuente

obtener valores con cierta desviación respecto del resto (*outliers*). De cualquier modo, cinco valores no son suficientes para poder sacar conclusiones con total certeza, aunque sí que lo serán para obtener conclusiones con cierto nivel de confianza.

La comparación de todos los experimentos efectuados queda reflejada en la figura 6.23. En ella se muestran los mínimos de los errores medios corregidos.




Figura 6.23: Histograma de errores medios corregidos.

EXPERIMENTO 1A




Figura 6.24: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 1A.

Se aprecia que 20 iteraciones no son suficientes para que la red aprenda. Con 50 se encuentra el mejor resultado (figura 6.24). Con un número mayor de iteraciones el error aumenta, lo cual se le puede otorgar al sobreentrenamiento. Con 200 iteraciones el error obtenido es algo mejor que el de 100; ésto en cambio se puede justificar como que es consecuencia del tamaño tan pequeño de muestra tomada de pruebas.

EXPERIMENTO 1B




Figura 6.25: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 1B.

Se aprecia que el número ostensiblemente superior de perceptrones no produce un mejor resultado sino todo lo contrario, la red se sobreentrena y no capta las relaciones necesarias para poder generalizar y predecir (ver histograma de la figura 6.23). Dentro de este experimento sí que se observa mejor el efecto de las iteraciones en el entrenamiento, es decir, con un número mayor de iteraciones el error sigue aumentando en todo momento, no como en el caso anterior.

EXPERIMENTO 1C




Figura 6.26: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 1C.

Se obtienen unos resultados con eficacia entre los otros dos (figura 6.26). Al igual que en el experimento anterior el incremento del número de iteraciones disminuye la calidad de los resultados.

EXPERIMENTO 1D




Figura 6.27: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 1D.

Aquí se ha tratado de evaluar la influencia del número de capas. En este caso es difícil sacar una conclusión certera, pero no se ha vislumbrado una mejora con el uso de una segunda capa oculta manteniendo el número total de perceptrones constante, es decir, el mismo número de perceptrones distribuidos con una topología distinta. Esto ya fue comentado en la sección 5.3.1, no siempre un número mayor de capas propicia una mejor solución.

EXPERIMENTO 1E




Figura 6.28: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 1E.

Se realizó con el mismo objetivo que el 1D. En este caso no se mantuvo un número total de perceptrones constante. La conclusión obtenida fue la misma que en el ejercicio anterior (1D).

EXPERIMENTO 1F

Las conclusiones obtenidas del 1F ya han sido comentadas en la sección 6.3.

EXPERIMENTOS 2A Y 2B




Figura 6.29: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 2A.




Figura 6.30: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 2B.

Se aprecia una notable mejora en los resultados con la inclusión de la humedad relativa (véase el histograma de la figura 6.23). No había sido introducida inicialmente en el modelo base dado que se ha estimado que no aportaría información que no diera ya la temperatura según lo visto en el análisis del apartado 6.2. Además, la humedad relativa del WRF posee un error mayor que la temperatura. En cualquier caso, la combinación de esta variable junto con las anteriores ha tenido un efecto positivo notable.

En concreto, en el 2A (figura 6.29) se aprecia que al tener pocas neuronas un número mayor de iteraciones produce una mejora en los resultados.

En cambio, con la topología de 15 neuronas en una capa oculta, que es el caso 2B (figura 6.30) parece que el caso es el contrario, obteniéndose sobreentrenamiento con un mayor número de iteraciones.

Comparando los dos, se obtienen mejores resultados para el caso de 5 perceptrones en una capa oculta.

EXPERIMENTOS 3A Y 3B




Figura 6.31: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 3A.




Figura 6.32: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 3B.

Se ha agregado la variable velocidad del viento. Se puede apreciar en el histograma de la figura 6.23 que el error permanece prácticamente constante.

Analizando los resultados de las redes creadas en ambos, en el 3A (figura 6.31) el resultado obtenido mejora hasta las pruebas con 100 iteraciones; en la de 200 se observa sobreentrenamiento.

En el 3B (figura 6.32) la mejor prueba es con 20 iteraciones. Esto puede ser debido a que la red contiene más perceptrones que en el 3A por lo que un número mayor de iteraciones produce rápidamente un sobreentrenamiento.

EXPERIMENTOS 4A Y 4B




Figura 6.33: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 4A.




Figura 6.34: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 4B.

Con el fin de obtener más información acerca de la variable velocidad del viento se realizaron los experimentos 4A y 4B (figuras 6.33 y 6.34). Se puede apreciar en el histograma de la figura 6.23 que el error vuelve a aumentar. Esto es debido a que se ha eliminado la humedad relativa en estos experimentos, la cual aporta bastante información.

EXPERIMENTOS 5A Y 5B




Figura 6.35: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 5A.




Figura 6.36: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 5B.

En estos experimentos ha sido añadida la variable dirección del viento respecto de los 4A y 4B, aunque sin albergar gran esperanza en la mejora de los resultados según lo observado en el análisis del apartado 6.2. Sin embargo, sí que se produce una mejora en la reducción del RMSE (ver histograma de la figura 6.23).

En el experimento 5A (figura 6.35) se produce sobreentrenamiento con las 100 iteraciones. En el 5B (figura 6.36) se alcanza la mejor solución con 50.

EXPERIMENTOS 6A Y 6B




Figura 6.37: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 6A.




Figura 6.38: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 6B.

Han sido efectuados añadiendo la humedad relativa además de cambiar los días y horas del año por el ángulo de elevación. En el histograma de la figura 6.23 se refleja la gran disminución del RMSE respecto de los 4 experimentos anteriores lo cual es lógico dado que en estos no se estaba añadiendo la humedad relativa. De todas maneras, se observa que ha disminuido respecto de los 2A, 2B, 3A y 3B por lo que añadir las variables dirección y velocidad del viento en adición con la elevación ha producido un efecto muy favorable.

El gráfico de la figura 6.37 y la experiencia de anteriores experimentos justifican la realización de sólo pruebas hasta 50 iteraciones ya que el error va aumentando. Por otra parte, el 6B (figura 6.38) al ser una red de mayor tamaño en este caso necesita un número mayor de iteraciones para mejorar algo los resultados.

EXPERIMENTOS 7A Y 7B




Figura 6.39: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 7A.




Figura 6.40: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 7B.

Se ha añadido la GHI respecto de los 6A y 6B. Se puede observar en el histograma de la figura 6.23 que el error aparentemente no mejora. Se habrían de realizar un número superior de pruebas para poder determinar esto con mayor exactitud.

EXPERIMENTOS 8A Y 8B




Figura 6.41: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 8A.




Figura 6.42: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 8B.

Se ha considerado que como la GHI depende de la DNI y DHI sería bueno repetir los experimentos 7A y 7B usando la DHI en lugar de la GHI.

En el caso del 8A (figura 6.41) el mejor resultado se obtiene con 100 iteraciones, volviendo a empeorar en las de 200. En cambio, en el 8B (figura 6.42) el menor error es con 20 iteraciones. Aquí, con 200 iteraciones el resultado mejora respecto de 100. Esto simplemente puede ser debido a que la muestra tomada es muy pequeña y poco representativa por tanto.

EXPERIMENTOS 9A Y 9B




Figura 6.43: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 9A.




Figura 6.44: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 9B.

La temperatura diferenciada ha sido insertada en lugar de la temperatura manteniendo el resto de variables iguales que en los 8A y 8B. Esto ha disminuido el error. En concreto, en el experimento 9B se han adquirido los mejores resultados de todos.

EXPERIMENTOS 10A Y 10B




Figura 6.45: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 10A.




Figura 6.46: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 10B.

Aquí se ha deseado estudiar el efecto de cambiar la variación de temperatura por la temperatura en los experimentos 1A y 1C en los experimentos 10A y 10B (figuras 6.45 y 6.46) respectivamente.

En el caso del 10A no se consigue ninguna mejora mientras que en el 10B sí (véase histograma de la figura 6.23). Por lo tanto, se ha supuesto que la variación de temperatura aporta más información que la variable temperatura.

EXPERIMENTOS 11A Y 11B




Figura 6.47: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 11A.




Figura 6.48: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 11B.

Aquí se ha querido comprobar si la variable dirección del viento aportaba algo de información o simplemente complicaba más el modelo. Por ello, se han repetido las pruebas de 9A y 9B pero suprimiendo dicha variable.

Atendiendo a lo visto en el histograma de la figura 6.23 el error vuelve a aumentar por lo que se ha considerado que la variable dirección del viento tiene relevancia dentro del modelo.

EXPERIMENTOS 12A, 12B, 12C Y 12D




Figura 6.49: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 12A.




Figura 6.50: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 12B.




Figura 6.51: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 12C.




Figura 6.52: Gráfico de dispersión RMSE (W/m^2) vs número de iteraciones realizadas en las pruebas de 12D.

Finalmente, se ha tratado de obtener unos resultados que mejoraran los obtenidos en el experimento 9B en los 12A, 12B y 12C (figuras 6.49, 6.50 y 6.51) usando sendas topologías diferentes. Cómo los resultados no han mejorado, se ha repetido la topología utilizada en el experimento 9B en el 12D (figura 6.52) con un número diferente de iteraciones.

RED SELECCIONADA

Los mejores resultados han sido obtenidos en los experimentos 9B y 12D. En realidad este no es más que el mismo experimento pero variando el número de iteraciones.

En concreto la red seleccionada ha sido la entrenada en la prueba 5 del experimento 12D. Los errores cometidos por la red y el MRM vienen dados en la tabla 6.34.

Tabla 6.34: Errores cometidos por MRM y la red neuronal.

-	RMSE	MBE
MRM	196.2513	26.8456
Red	142.3172	-4.5807

El tanto por ciento que ha disminuido el RMSE es:

$$\Delta RMSE(\%) = \frac{196,2513 - 142,3172}{196,2513} = 27,5\% \quad (6.1)$$

Y el del MBE en valores absolutos:

$$\Delta MBE(\%) = \frac{26,8456 - 4,5807}{26,8456} = 82,9\% \quad (6.2)$$

Se ha comprobado a lo largo de la investigación experimental que todas las redes neuronales subestiman la predicción. En cambio el MRM la sobreestima significativamente. Esto se puede observar mejor según el diagrama mostrado en la figura 6.53. Esto es debido al gran número de datos en los que el índice nubosidad no acierta con la estimación de las nubes, proveyendo valores menores a los correspondientes. Es más, según lo visto en el gráfico de la figura 6.8, la predicción del MRM mejora notablemente con valores de DNI medidos altos, es decir, en condiciones de cielo despejado.




Figura 6.53: DNI estimada frente DNI medida obtenida de la red neuronal y del MRM.

Se puede observar lo dicho, es decir, una notable reducción en los valores correspondientes a DNI real bajos, que el MRM pronostica como cielo claro. Por otra parte sucede lo contrario aunque en menor medida, o sea, son medidos valores altos y el MRM los predice como bajos. Cabe mencionar el gran número de valores que ya no son tomados con valor nulo en la red, mientras que en el MRM sí los toma. También ocurre que para valores de DNI medidos nulos, los valores de la predicción de la red son menores que los pronosticados por el MRM. Finalmente, se puede apreciar una pendiente ligeramente inferior a la unidad en la recta de regresión de la red, cuya explicación se encuentra en lo ya comentado: la red subestima levemente los valores previstos. Esto queda reflejado en el análisis de regresión realizado mediante Matlab (figura 6.54). Los coeficientes de R^2 tienen un valor de 0,7257 y 0,8298 para los datos directamente del MRM y la red neuronal respectivamente.

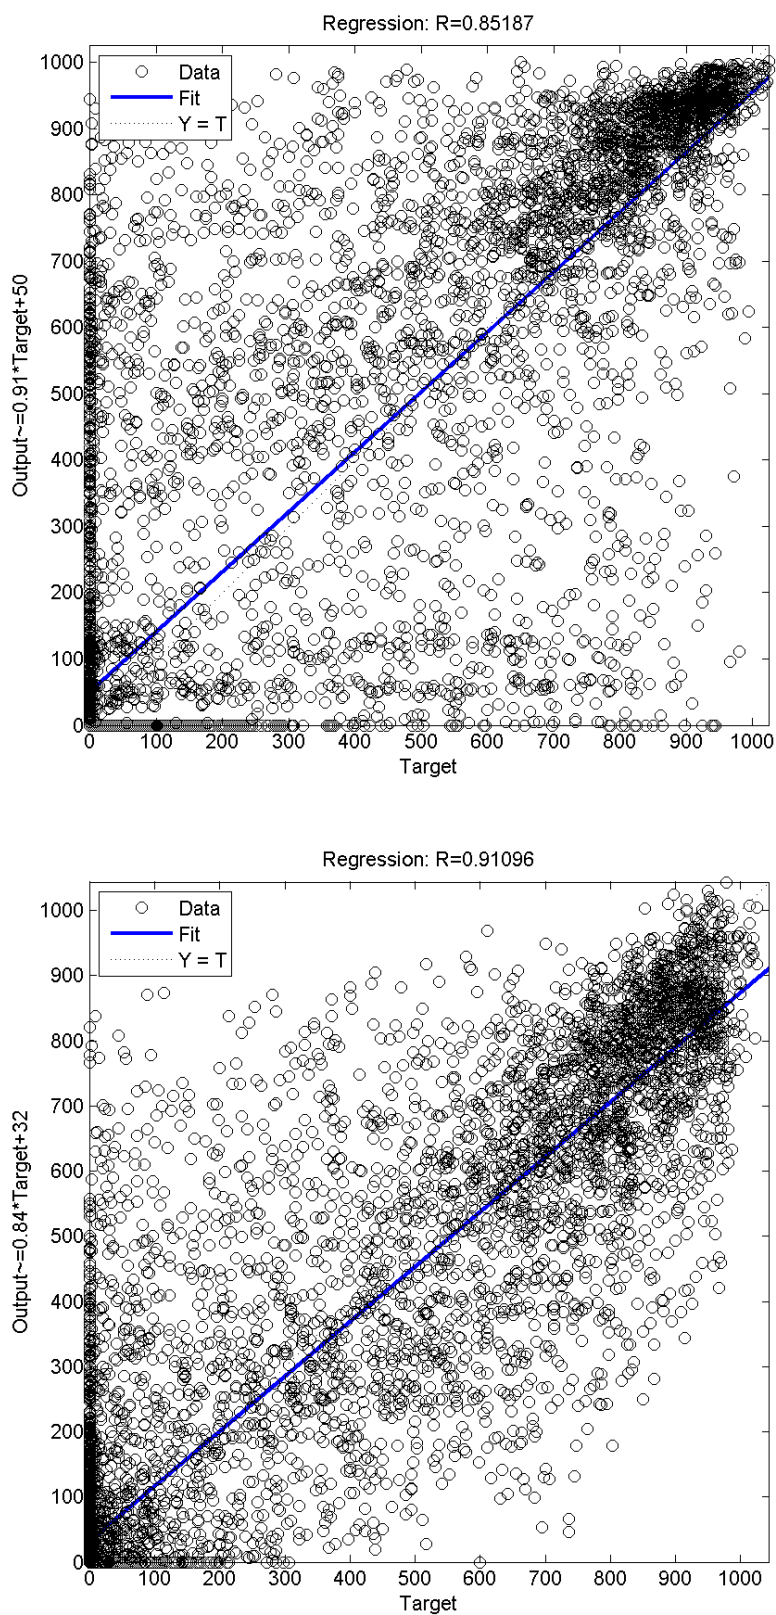


Figura 6.54: Análisis de regresión para los datos obtenidos directamente del MRM (arriba) y con la red neuronal (abajo).

Para facilitar la visualización de los resultados, los perfiles diarios de DNI son presentados en las figuras 6.55, 6.56, 6.57, 6.58, 6.59, 6.61, 6.62, 6.63, 6.64, 6.65 y 6.66.

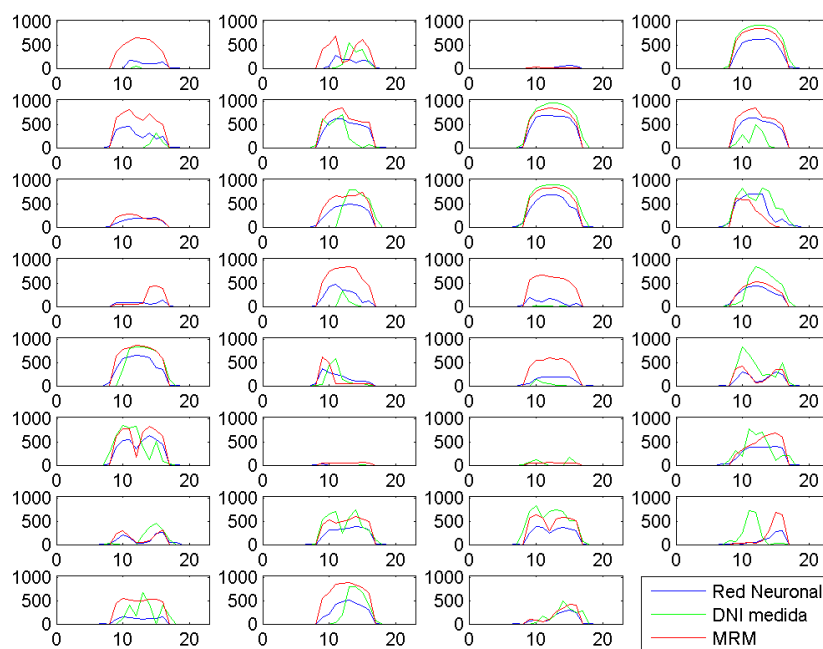


Figura 6.55: Perfiles diarios de DNI (W/m^2) para el mes de Enero.

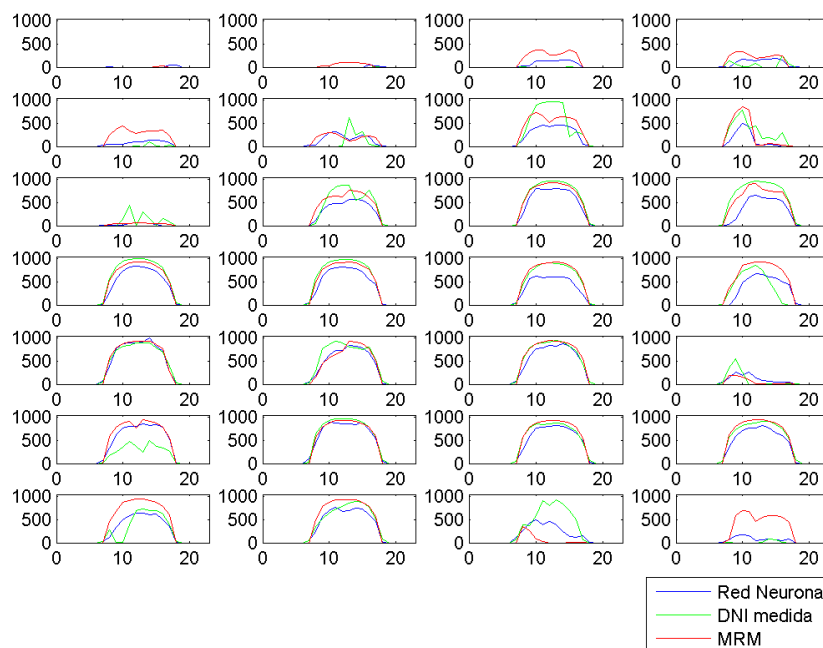


Figura 6.56: Perfiles diarios de DNI (W/m^2) para el mes de Febrero.

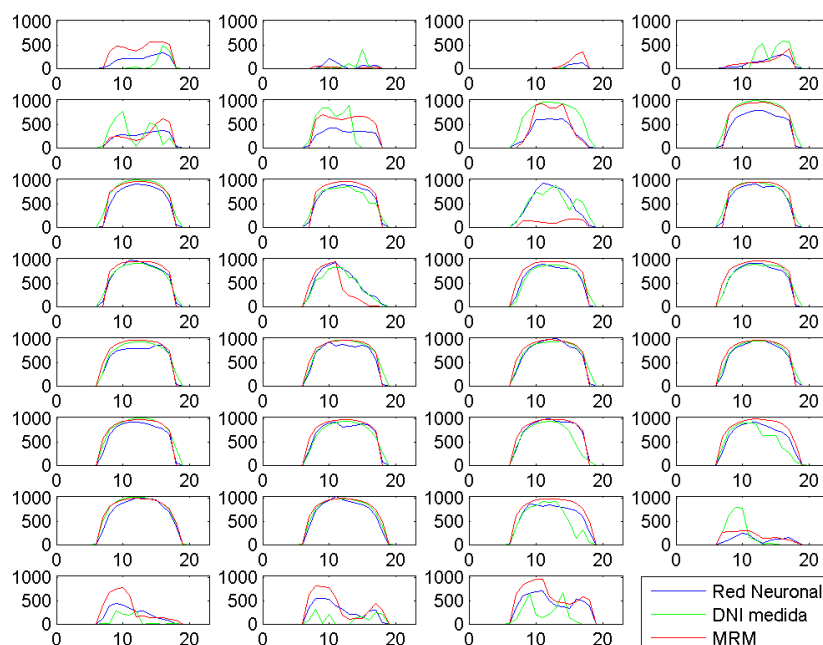


Figura 6.57: Perfiles diarios de DNI (W/m^2) para el mes de Marzo.

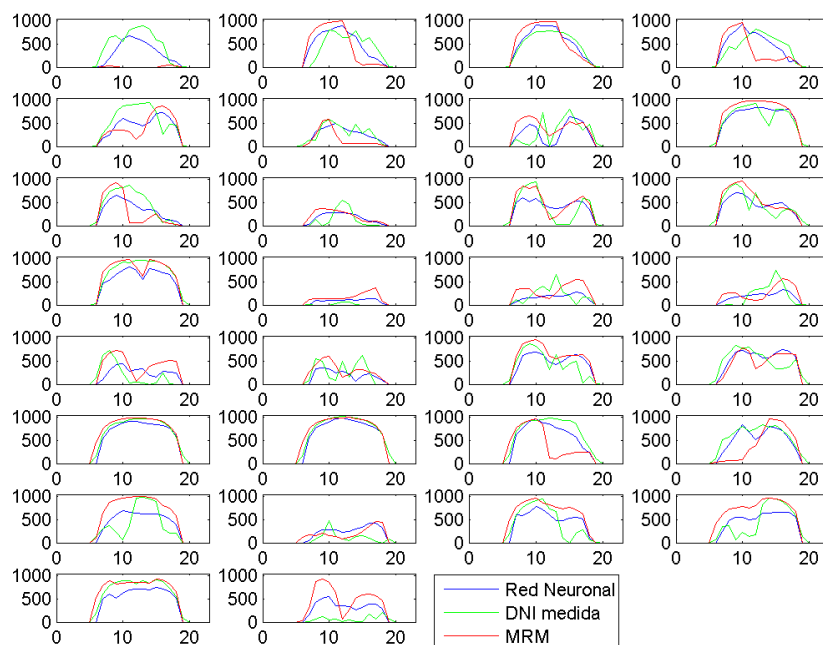


Figura 6.58: Perfiles diarios de DNI (W/m^2) para el mes de Abril.

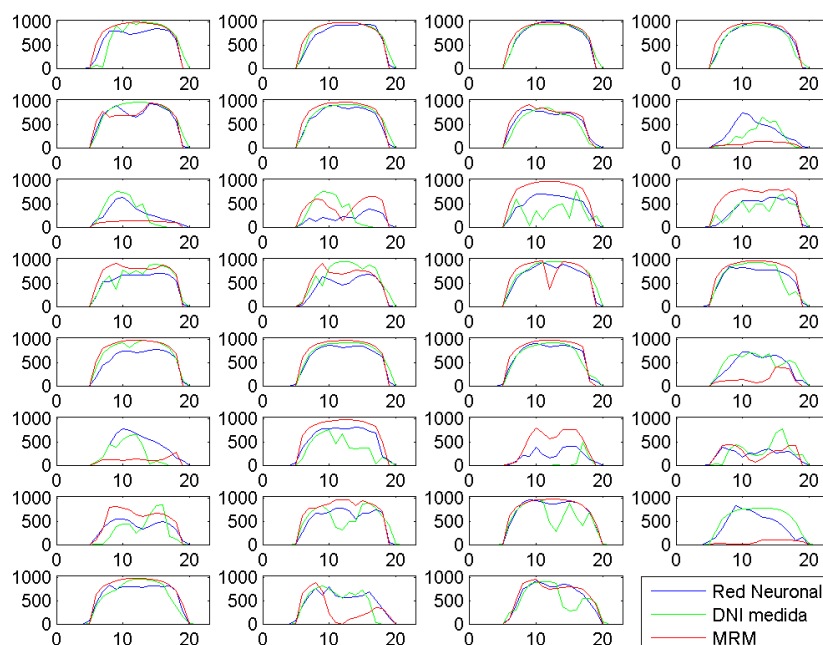


Figura 6.59: Perfiles diarios de DNI (W/m^2) para el mes de Mayo.

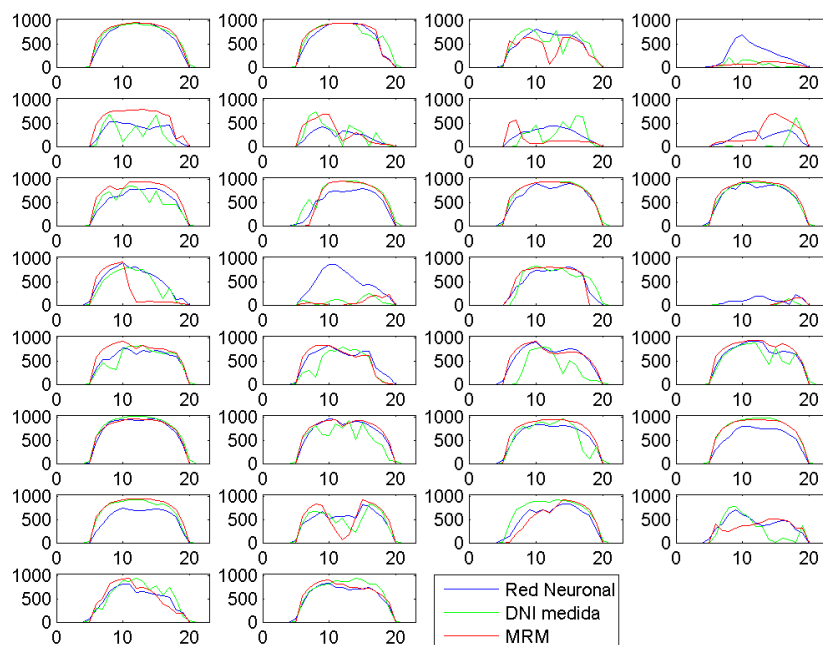


Figura 6.60: Perfiles diarios de DNI (W/m^2) para el mes de Junio.

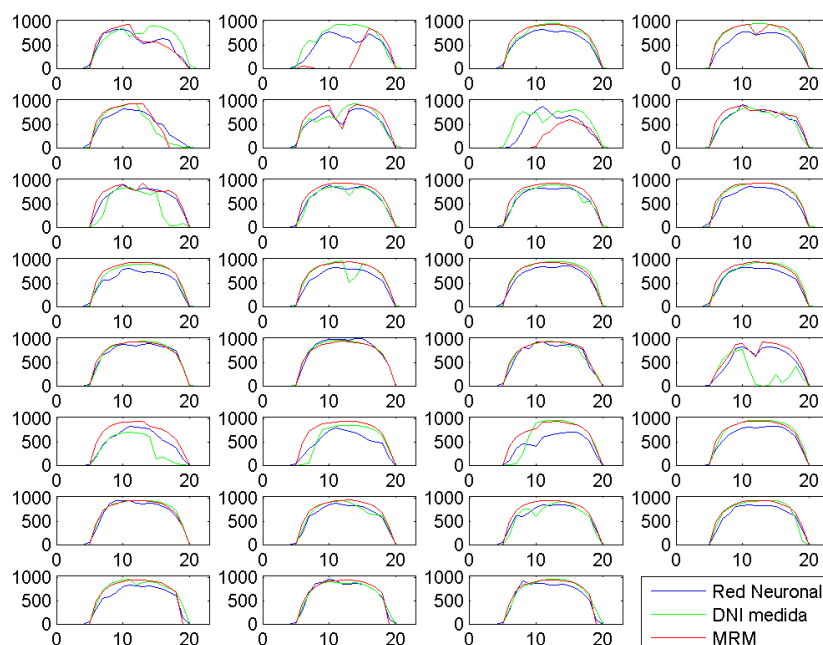


Figura 6.61: Perfiles diarios de DNI (W/m^2) para el mes de Julio.

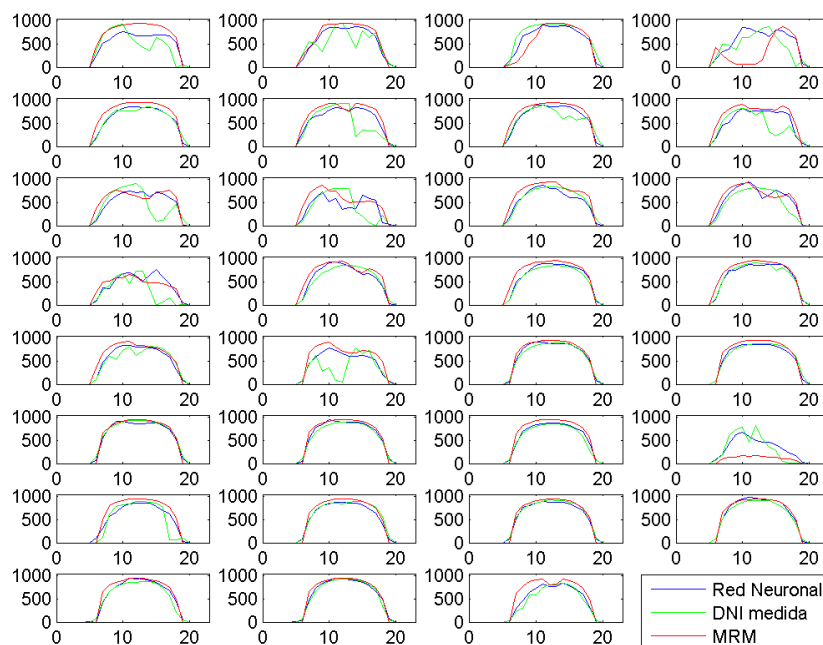


Figura 6.62: Perfiles diarios de DNI (W/m^2) para el mes de Agosto.

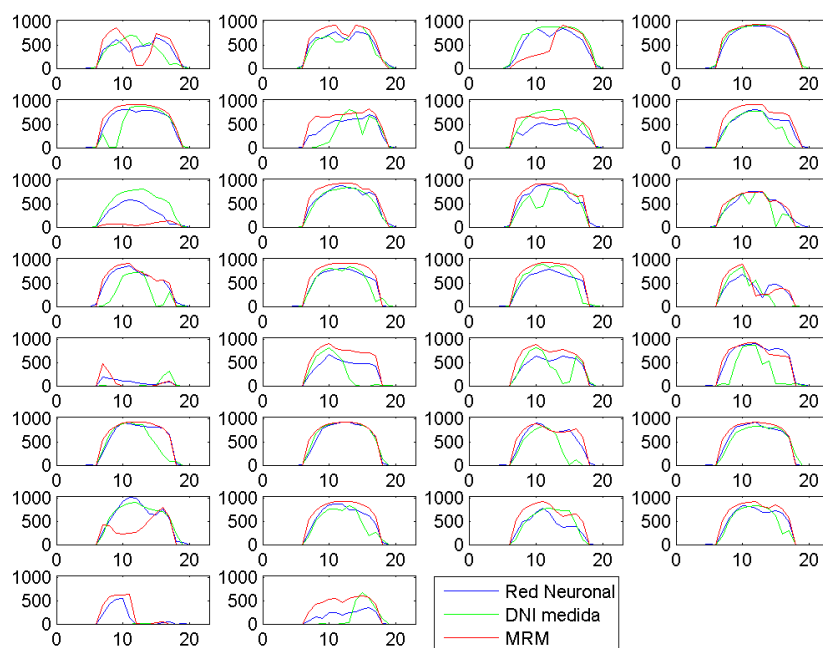


Figura 6.63: Perfiles diarios de DNI (W/m^2) para el mes de Septiembre.

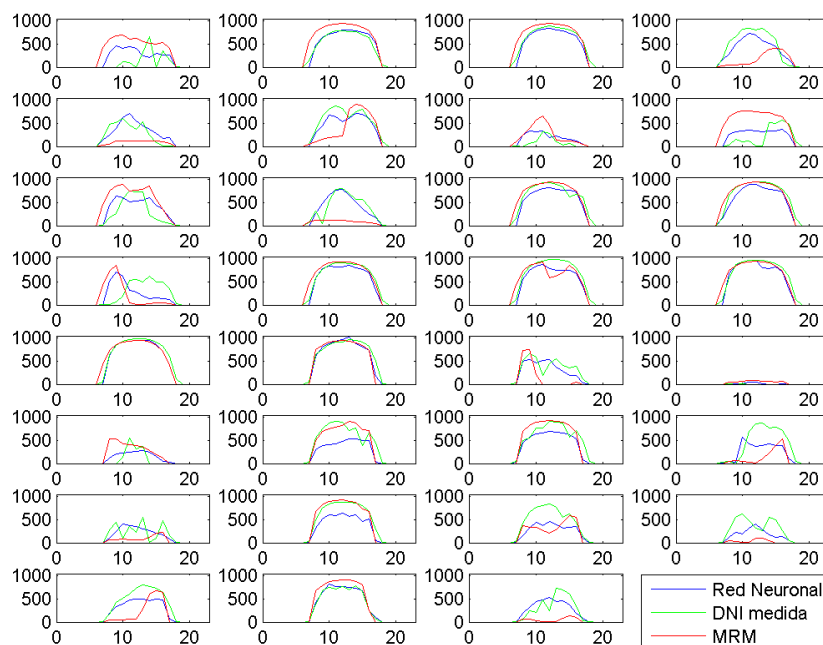


Figura 6.64: Perfiles diarios de DNI (W/m^2) para el mes de Octubre.

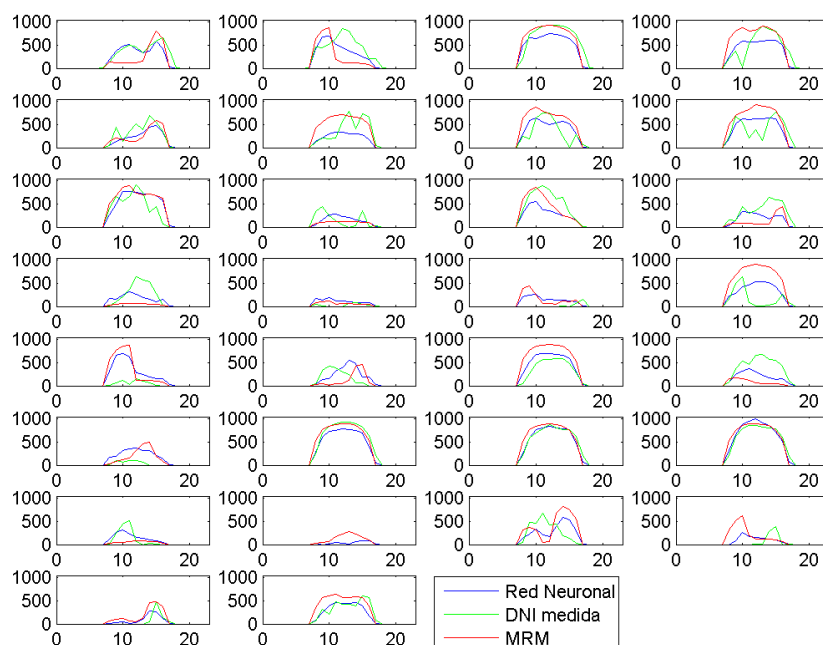


Figura 6.65: Perfiles diarios de DNI (W/m^2) para el mes de Noviembre.

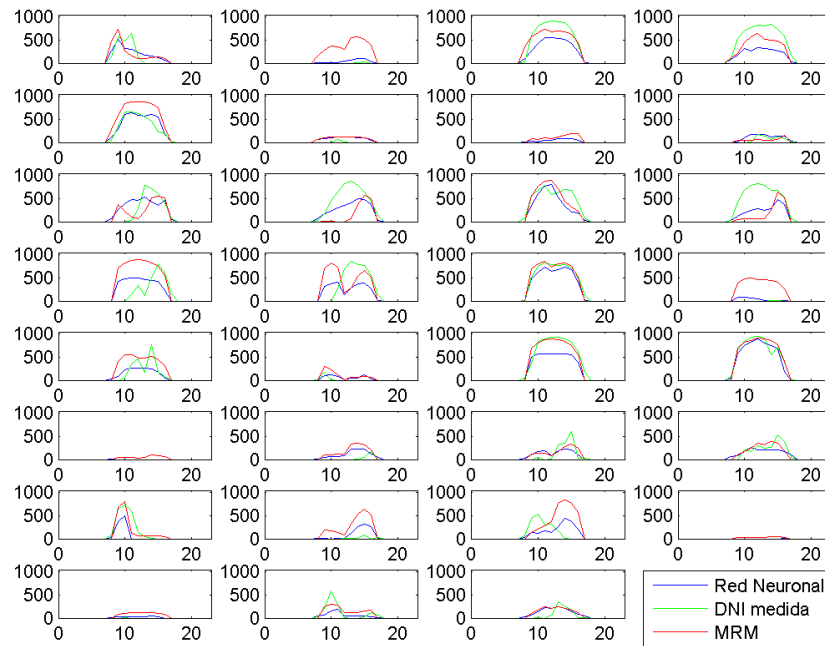


Figura 6.66: Perfiles diarios de DNI (W/m^2) para el mes de Diciembre.

CAPÍTULO 7

CONCLUSIONES Y TRABAJOS FUTUROS

El objetivo de este proyecto es la selección de los parámetros y variables adecuados para el entrenamiento de una red neuronal que mejore la estimación dada por un sistema de predicción meteorológica. En concreto se tratará de predecir la Irradiancia Directa Normal que es la componente de la irradiancia solar que se puede concentrar y acumular en los almacenamientos de las plantas termosolares.

Para llevar dicha labor a cabo, en primer lugar la simulación de las variables meteorológicas necesarias ha sido efectuada; posteriormente se ha usado un modelo físico para la predicción de la DNI; finalmente con dichos datos se ha realizado un estudio de la parametrización del entrenamiento y topología de la red neuronal mediante el empleo del toolbox de Matlab para redes neuronales. Los efectos de las iteraciones y número de perceptrones han sido examinados entre otros parámetros.

7.1. CONCLUSIONES

Las conclusiones extraídas de los resultados obtenidos son las siguientes:

- Se ha observado que no se puede definir una tendencia exacta respecto al número de iteraciones y topología de la red.
- Existen diferencias provocadas por la morfología de la red pero en este caso no han sido el factor más determinante.
- Cada variable añadida aporta una información que puede cambiar en el número de épocas óptimo que son necesarias.
- Se ha detectado una cierta inclinación a la obtención de los mejores resultados con el menor número de iteraciones en el caso de los ensayos con 15 perceptrones por capa, obteniéndose estos con un número mayor en las pruebas de 5 perceptrones.
- Se vislumbra un aumento en el número de iteraciones necesarias con el aumento en el número de variables de entrada en el caso de 15 perceptrones, lo cual parece razonable.

- El número de iteraciones con los que se obtienen los mejores resultados es un número ínfimo respecto al que se puede obtener en otros problemas. Esto se atribuye a que el problema a resolver no entraña demasiada dificultad una vez se han inicializado los pesos de la red al modelo físico.
- Todas las redes entrenadas subestiman la energía a acumular en menor medida que el MRM la sobreestima.

Además, otras opiniones han sido extraídas de todo el proceso de documentación y desarrollo:

- Se ha comprobado el potencial de las redes neuronales, demostrándose como captan relaciones entre variables que aparentemente no guardan ninguna relación y de manera muy simple para el modelizador. Sin embargo, durante la realización del presente proyecto se ha intuido que realizar la predicción de series temporales de un problema partiendo desde cero requiere de ciertos niveles de habilidad y experiencia, además de mucha paciencia.
- Se ha comprobado la alta capacidad de cálculo que encierra y simplicidad de uso de la aplicación Matlab. El desarrollo de herramientas para tareas relativamente específicas (como puede ser el diseño de una red neuronal) en un entorno de programación integrado facilita con creces la labor del modelizador, dotándole de un mayor abanico de posibilidades a la hora de trabajar.
- El problema de la predicción meteorológica es ciertamente complicado, como se ha visto la resolución de las ecuaciones diferenciales no es nada trivial. Sin embargo, sí que se han producido grandes avances en esta materia.
- El problema de la predicción de la irradiancia solar directa a pesar de parecer muy simple a priori, no lo es tanto, ya que es una cuestión relativamente nueva; es una cuestión que ha nacido con la tecnología termosolar y mucho queda aún por investigar y conocer.

7.2. TRABAJOS FUTUROS

Los resultados de la red neuronal a pesar de mejorar significativamente los del MRM no son tan buenos como cabía esperar. Esto se achaca al tamaño limitado de la muestra. Facilitaría notablemente el entrenamiento de la red realizarlo con una base de datos mayor en el tiempo (3 o 4 años de datos reales) y con datos de variables meteorológicas medidas directamente y no estimadas mediante modelos numéricos, ya que estos tienen una incertidumbre mayor que un aparato de medida. Esto se podría encontrar sin problemas en una central termosolar ya operativa.

Desde un punto de vista científico lo idóneo es la instalación de una amplia red de estaciones meteorológicas a lo largo de los emplazamientos de interés para el desarrollo de modelos estadísticos fiables. No obstante, esto es muy costoso y poco rentable para las empresas. Esto supone tener que seguir trabajando con un tamaño limitado de muestra por lo que se deberá seguir probando a realizar experimentos en esta línea.

Ha habido un auge en el desarrollo de la inteligencia artificial en la última década (i.e, algoritmos genéticos, otro tipo de redes como las autoorganizativas...) que pueden ser usados independientemente o en combinación con la red *feedforward*. Estas técnicas ya están siendo de hecho probadas en aplicaciones de toma de decisiones y otras con fines económicos, además de alguno de sus campos naturales como puede ser la robótica.

Otra línea de investigación más costosa y compleja es la de utilizar técnicas de *Now-casting* o pronóstico a muy corto plazo. Consiste en la utilización de imágenes del canal visible de satélites geoestacionarios para en combinación con imágenes tomadas desde tierra poder realizar un seguimiento de las nubes. En adición, mediante el empleo de tratamiento de imágenes pueden utilizarse o bien redes neuronales o bien la inferencia bayesiana (mediante redes bayesianas) para la clasificación de tipos de nubes. A cada nube pronosticada se le asignará un rango de factor de descuento u otro.

ANEXO A

PARÁMETROS DEL WPS

```
&share
  wrf_core = 'ARW',
  max_dom = 1,
  start_date=2008-01-01_00:00:00,
  end_date=2008-02-01_00:00:00,
  interval_seconds = 3600
  io_form_geogrid = 2,
/
```

```
&geogrid
  parent_id      = 1, 1,
  parent_grid_ratio = 1, 3,
  i_parent_start  = 1, 31,
  j_parent_start  = 1, 17,
  e_we=15, 112,
  e_sn=15, 97,
  geog_data_res   = '10m','2m',
  dx=5000,
  dy=5000,
  map_proj = 'lambert',
  ref_lat  = 40.4528,
  ref_lon  = -3.7242,
  truelat1 = 45.4528,
  truelat2 = 35.4528,
  geog_data_path = '../geog_data'
/
```

```
&ungrib
  out_format = 'WPS',
  prefix = 'FILE',
/
```

```
&metgrid
  fg_name = 'FILE'
  io_form_metgrid = 2,
```


ANEXO B

PARÁMETROS DEL WRF

```
&time_control
  run_days=31,
  run_hours      = 0,
  run_minutes    = 0,
  run_seconds    = 0,
  start_year=2008,
  start_month=01,
  start_day=01,
  start_hour=00,
  start_minute   = 00,   00,   00,
  start_second   = 00,   00,   00,
  end_year=2008,
  end_month=02,
  end_day=01,
  end_hour=00,
  end_minute     = 00,   00,   00,
  end_second     = 00,   00,   00,
  interval_seconds = 3600
  input_from_file = .true.,.true.,.true.,
  history_interval = 60,  60,  60,
  frames_per_outfile = 1000, 1000, 1000,
  restart          = .false.,
  restart_interval = 5000,
  io_form_history  = 2
  io_form_restart  = 2
  io_form_input    = 2
  io_form_boundary = 2
  debug_level      = 0
/

&domains
  time_step=30,
  time_step_fract_num = 0,
  time_step_fract_den = 1,
  max_dom             = 1,
```

```

e_we=15,
e_sn=15,
e_vert           = 28,    28,    28,
p_top_requested  = 5000,
num_metgrid_levels = 27,
num_metgrid_soil_levels=4,
dx=5000,
dy=5000,
grid_id          = 1,     2,     3,
parent_id        = 0,     1,     2,
i_parent_start   = 1,     31,    30,
j_parent_start   = 1,     17,    30,
parent_grid_ratio = 1,     3,     3,
parent_time_step_ratio = 1,   3,     3,
feedback         = 1,
smooth_option    = 0,
interp_type      = 2,
extrap_type      = 2,
t_extrap_type    = 2,
use_levels_below_ground = .true.,
use_surface      = .true.,
lagrange_order   = 1,
/

&physics
mp_physics       = 3,     3,     3,
ra_lw_physics    = 1,     1,     1,
ra_sw_physics    = 1,     1,     1,
radt            = 5,     30,    30,
sf_sfclay_physics = 1,     1,     1,
sf_surface_physics = 2,     2,     2,
bl_pbl_physics   = 1,     1,     1,
bldt            = 0,     0,     0,
cu_physics       = 1,     1,     0,
cudt            = 5,     5,     5,
isfflx          = 1,
ifsnow          = 1,
icloud          = 1,
surface_input_source = 1,
num_soil_layers  = 4,
sf_urban_physics = 0,
maxiens         = 1,
maxens          = 3,
maxens2         = 3,
maxens3         = 16,
ensdim          = 144,
/

```



```
&fdda
/

&dynamics
w_damping          = 0,
diff_opt           = 1,
km_opt             = 4,
diff_6th_opt       = 0,      0,      0,
diff_6th_factor    = 0.12,  0.12,  0.12,
base_temp          = 290.
damp_opt           = 0,
zdamp              = 5000., 5000., 5000.,
dampcoef           = 0.2,   0.2,   0.2
khdif              = 0,     0,     0,
kvdif              = 0,     0,     0,
non_hydrostatic    = .true., .true., .true.,
moist_adv_opt       = 1,     1,     1,
scalar_adv_opt      = 1,     1,     1,
/

&bdy_control
spec_bdy_width     = 5,
spec_zone          = 1,
relax_zone         = 4,
specified          = .true., .false., .false.,
nested             = .false., .true., .true.,
/

&grib2
/

&namelist_quilt
nio_tasks_per_group = 0,
nio_groups = 1,
/
```


ANEXO C

PARÁMETROS DE TURBIDEZ OBTENIDOS

Tabla 7.1: Parámetros de aeorosos para el año 2007.

Mes	AOT550	Angstrom	Beta
Enero	0.053	2.030	0.013
Febrero	0.087	2.087	0.012
Marzo	0.146	2.167	0.014
Abril	0.071	2.562	0.019
Mayo	0.104	2.562	0.022
Junio	0.156	2.524	0.022
Julio	0.254	2.092	0.019
Agosto	0.185	2.033	0.032
Septiembre	0.126	2.070	0.032
Octubre	0.116	1.779	0.014
Noviembre	0.098	1.944	0.010
Diciembre	0.143	1.760	0.008

Tabla 7.2: Parámetros de aeorosos para el año 2006.

Mes	AOT550	Angstrom	Beta
Enero	0.081	1.798	0.027
Febrero	0.080	2.239	0.021
Marzo	0.063	2.386	0.015
Abril	0.047	2.613	0.001
Mayo	0.070	2.468	0.015
Junio	0.131	2.366	0.031
Julio	0.110	2.293	0.027
Agosto	0.096	2.420	0.022
Septiembre	0.143	1.928	0.045
Octubre	0.112	2.092	0.032
Noviembre	0.080	2.122	0.022
Diciembre	0.078	2.356	0.019

Tabla 7.3: Parámetros de aeorosos para el año 2005.

Mes	AOT550	Angstrom	Beta
Enero	0.106	2.030	0.031
Febrero	0.095	1.990	0.032
Marzo	0.091	1.799	0.025
Abril	0.053	2.121	0.019
Mayo	0.051	2.515	0.011
Junio	0.105	2.529	0.028
Julio	0.100	2.216	0.023
Agosto	0.127	2.450	0.031
Septiembre	0.131	2.320	0.036
Octubre	0.076	2.156	0.020
Noviembre	0.069	2.226	0.018
Diciembre	0.082	2.163	0.022

Tabla 7.4: Parámetros de aeorosos para el año 2004.

Mes	AOT550	Angstrom	Beta
Enero	0.256	1.405	0.111
Febrero	0.144	1.400	0.062
Marzo	0.028	1.407	0.012
Abril	0.121	1.528	0.048
Mayo	0.115	1.544	0.046
Junio	0.194	1.610	0.074
Julio	0.153	1.507	0.062
Agosto	0.119	1.502	0.048
Septiembre	0.086	1.426	0.037
Octubre	0.095	1.423	0.040
Noviembre	0.013	1.425	0.054
Diciembre	0.075	1.431	0.032

Tabla 7.5: Parámetros de aeorosos para el año 2003.

Mes	AOT550	Angstrom	Beta
Enero	0.256	1.405	0.111
Febrero	0.144	1.400	0.062
Marzo	0.028	1.407	0.012
Abril	0.121	1.528	0.048
Mayo	0.115	1.544	0.046
Junio	0.194	1.610	0.074
Julio	0.153	1.507	0.062
Agosto	0.119	1.502	0.048
Septiembre	0.086	1.426	0.037
Octubre	0.095	1.423	0.040
Noviembre	0.013	1.425	0.054
Diciembre	0.075	1.431	0.032

BIBLIOGRAFÍA

- [1] Página web de la Asociación Española de la Industria Solar Termoeléctrica, www.protermosolar.com
- [2] Detlev Heinemann, *Lecture Notes*, Postgraduate Programme ‘Renewable Energy’, Carl von Ossietzky Universität, Oldenburg, 2000.
- [3] H. D Kabezidis and B. E. Psiloglou, *The Meteorological Radiation Model (MRM): Advancements and Applications*.
- [4] Eugenia Kalnay, *Atmospheric modeling, data assimilation and predictability*, 2003.
- [5] Martin J. Mohlenkamp, *A User’s Guide to Spherical Harmonics*, 2010.
- [6] Página web de NOAA, <http://www.emc.ncep.noaa.gov/GFS/doc.php>
- [7] National Center for Atmospheric Research, *ARW User’s Guide*, 2008.
- [8] J.Beres, *Comparison of WRF Model Outputs and MODIS Image Products for Cloud Presence*, 2008.
- [9] J.M Gutiérrez, R. Cano, A. S. Cofiño y C. M. Sordo, *Redes probabilísticas y neuronales en las ciencias atmosféricas*, 2004.
- [10] Warren S.McCulloch, Walter H. Pitts, *A logical calculus of the ideas immanent in nervous activity*, 1943.
- [11] F. Rosenblatt *The perceptron: a probabilistic model for information storage and organization in the brain*, 1958.
- [12] Marvin Minsky, Seymour Papert *Perceptrons: an introduction to computational geometry*, 1969.
- [13] J. J. Hopfield, *Neural networks and physical systems with emergent collective computational abilities*, 1982.
- [14] Guoqiang Zhang, B. Eddy Patuwo and Michael Y. Hu, *Forecasting with artificial neural networks: The state of the art*, 1998
- [15] P. P. Jurewicz y J. G. Bueno, *Neural evolution*, 2010.
- [16] Miguel Alcubierre, *Métodos numéricos en relatividad*, 2005.
- [17] <http://www.meteored.com/>
- [18] Página web del proyecto Globaerosol, <http://www.globaerosol.info/>

- [19] H. Barroso, *Modelización de un campo solar de concentración*, 2010.
- [20] D. Carrasco, *Modelos estadísticos de predicción aplicados a una central termosolar*, 2010.